



UNIVERSITÀ DI PISA

Dipartimento di Scienze Agrarie, Alimentari e Agro-ambientali

Corso di Laurea Magistrale: Produzioni Agroalimentari e Gestione degli Agroecosistemi

Tesi di Laurea Magistrale

*Procedure per il rilevamento delle piante infestanti a partire da immagini
acquisite da drone*

Relatore: *Dott. Nicola Silvestri*

Correlatore: *Dott. Riccardo Salvini*

Candidato: *Simone Favero*

ANNO ACCADEMICO 2019-2020

INDICE

1. Introduzione	1
1.1 Sistemi agricoli intensivi	1
1.2 Agricoltura di precisione	4
1.3 I droni	7
1.4 Utilizzo dei droni in agricoltura	10
1.5 Rilevamento delle specie vegetali infestanti con l'impiego di droni	14
1.6 Problematiche delle malerbe	15
1.7 Procedure e problematiche per il rilevamento delle piante infestanti a partire da immagini acquisite da drone	16
1.8 Pre-processing: <i>pre-elaborazione</i>	17
1.9 Vegetation segmentation: <i>segmentazione della vegetazione</i>	19
1.10 Considerazione sugli approcci elencati	33
1.11 Estrazione delle caratteristiche	34
1.12 Classificazione	38
2. Scopo della ricerca	43
3. Materiali e metodi	44
3.1 Organizzazione della superficie di lavoro	45
3.2 Proprietà pedologiche degli appezzamenti	46
3.3 Drone "Agri-Efesto"	47
3.4 Voli effettuati	48
3.5 Modalità di volo	48
3.6 Selezione delle immagini per scopi di fotogrammetria	49
3.7 Metodologia pre-Deep Learning	50
3.8 Fraction Vegetation Cover (FVC)	57
3.9 Programmi utilizzati: Labelbox e GIMP	58
3.10 Analisi statistica	60
3.11 Immagini analizzate	61
4. Risultati	64
4.1 Differenza risultati di volo tra 10 m, 15 m e 20 m	66
4.2 Differenza tra le parcelle diserbate e non diserbate dei voli a 10 m del secondo volo	70
4.3 Differenza tra il primo volo con il secondo volo	72

4.4 Dettaglio della performance della rete neurale in una parcella	77
4.5 Confronto tra immagini segmentate dalla rete neurale e manualmente	80
5. Discussione	85
5.1 Discussioni sulla differenza dei risultati di volo tra 10 m, 15 m e 20 m.	85
5.2 Differenza tra le parcelle diserbate e non diserbate dei voli a 10 m del secondo volo..	88
5.3 Considerazioni sulle differenze osservate tra il primo e il secondo volo	89
5.4 Performance della rete neurale in una parcella ed in un quadrante	90
5.5 Confronto tra immagini segmentate dalla rete neurale e manualmente	91
5.6 Difficoltà ambientali	93
5.7 Confronto tra i diversi approcci	94
6. Conclusioni.....	95
7. Bibliografia	96
8. Allegato.....	107

1. Introduzione

1.1 Sistemi agricoli intensivi

Nel corso della storia, in particolare nell'ultimo secolo, l'agricoltura ha subito un significativo cambiamento dal punto di vista ambientale, socioculturale ed economico procedendo sempre di più verso un'agricoltura intensiva (Ferrari, 2018). L'agricoltura intensiva è un modello di agricoltura finalizzato alla massimizzazione delle produzioni agricole e del reddito (Caporali, 1991). Come descritto nella tabella 1.1, elaborata da Caporali (1991), vi sono diverse caratteristiche che rappresentano i sistemi agricoli intensivi, generando diversi effetti e conseguenze sull'agroecosistema.

Tabella 1.1: *effetti sull'agroecosistema e conseguenze dei sistemi agricoli intensivi (Caporali, 1991).*

Caratteristiche delle aziende intensive	Effetti sull'agroecosistema	Conseguenze
1. Separazione allevamento vegetale e animale	Interruzione della catena del pascolo e del detrito	> <i>impiego mangimi</i> > <i>impiego concimi</i>
2. Rinuncia alle colture foraggere poliennali	< cicizzazione > erosione	> <i>impiego concimi</i> > <i>lavorazioni</i> > <i>irrigazione</i>
3. Semplificazione avvicendamenti colturali, monosuccessione	< biodiversità > specializzazione infestanti, parassiti e malattie	> <i>impiego concimi</i> > <i>insetticidi</i> > <i>fungicidi</i> <i>introduzione OGM</i>
4. Rinuncia a consociazioni e sovesci:	< biodiversità < cicizzazione < uso delle risorse native	> <i>impiego concimi</i> > <i>insetticidi</i> > <i>fungicidi</i>

1.1.1 Impatto ambientale

Questo modo di concepire l'agricoltura, inteso come sistema industriale, ha provocato un forte impatto sull'ambiente, quali: l'erosione del suolo, che riguarda il 45% dei terreni agricoli e che può diminuire la resa effettiva dei raccolti dal 8-21%; la riduzione della fertilità dei suoli; l'impiego massiccio di energia non rinnovabile; la lisciviazione delle sostanze nutritive e l'eutrofizzazione (Caporali et al. 1991).

A ciò si aggiungono problemi strutturali di notevole importanza a carico della disponibilità delle risorse naturali, in particolare (Ferrari, 2018):

- carenza di risorse idriche: con effetti irreversibili sulle falde acquifere;
- incremento della salinità dei suoli e delle acque: a causa di pratiche agricole inappropriate con la conseguente degradazione degli agro-ecosistemi;
- degradazione dei suoli: con effetti sulla riduzione della produzione alimentare;
- contaminazione dell'ambiente: attraverso l'abbondante utilizzo di fertilizzanti e diserbanti.

1.1.2 Impatto socioculturale ed economico

Dal punto di vista socioculturale ed economico, l'implementazione di modelli di produzione non sostenibili ha generato effetti importanti e contrastanti, come ad esempio la produzione di alimenti *insecurity* e *unsafety*, le relazioni interpersonali fragili, le differenze di status economico e sociale determinano condizioni di insicurezza e precarietà. In particolare, questi modelli di Agrifood hanno delle conseguenze di tipo economico come ad esempio una maggiore oscillazione del costo degli alimenti, l'aumento del prezzo dei mezzi tecnici, la crisi delle singole o piccole aziende e la progressiva perdita dello scambio locale (Caporali et al. 1991).

In accordo con quanto affermato da Ferrari (2018): “l'agricoltura moderna si trova ad affrontare enormi sfide per costruire un futuro sostenibile” possiamo dire che il tema ambientale deve essere visto come un pilastro fondamentale dello sviluppo e della sostenibilità.

1.1.3 Sfide globali

Tra le sfide globali più importanti abbiamo l'accrescimento della popolazione, la degradazione degli agro-ecosistemi e soprattutto il cambiamento climatico. A causa del cambiamento climatico, l'agricoltura sta cercando di trovare nuove soluzioni al fine di limitare gli impatti sui sistemi agricoli. Gli attuali modelli Agrifood contribuiscono alla produzione di sostanze dannose per l'ambiente, in particolare i gas serra, dovuti prevalentemente all'incremento degli allevamenti intensivi, alla contaminazione prodotta dai mezzi di produzione e agli sprechi alimentari (Ferrari, 2018).

Nel 2050, la popolazione mondiale si avvicinerà quasi ai nove miliardi (Alexandratos e Bruinsma, 2012) e di conseguenza la Food and Agriculture Organization (FAO) ha stimato che la domanda dei prodotti agricoli aumenterà del 60% in 45 anni (2005-2050). Allo stesso tempo, secondo "Lo Stato Mondiale delle Risorse Terrestri e Idriche" della "Organizzazione delle Nazioni Unite per l'Alimentazione e l'Agricoltura", FAOSTAT (2017), è stata osservata una riduzione della terra arabile necessaria al sostentamento alimentare di una persona, passando da 0,45 ettari nel 1961 a 0,22 ettari nel 2006.

1.1.4 Tecnologia e agricoltura

Per affrontare queste sfide è indispensabile rivoluzionare il modo di concepire l'agricoltura attraverso l'adozione di dispositivi, sensori, tecnologie, processi di produzione che derivano dal progresso scientifico in maniera tale da diminuire i costi, i consumi ed incrementarne la produzione (Coudel et al., 2013), portando gli agricoltori a cercare nuovi metodi di coltivazione che siano conciliabili con l'ottenimento di un prodotto finale di qualità ottimale dal punto di vista sanitario, economico e con un ridotto impatto ambientale. A tal fine vi è sempre di più la necessità dell'utilizzo della tecnologia per far fronte alle questioni ambientali (Bejtja Silva, 2018). Dunque, in questo momento di criticità, l'agricoltura non può fare a meno di pensare all'agricoltura di precisione come una delle soluzioni possibili (Ferrari, 2018).

1.2 Agricoltura di precisione

1.2.1 Definizione di agricoltura di precisione

Secondo le linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle politiche agricole alimentari e forestali: “l'Agricoltura di Precisione (AdP) è un sistema di gestione integrato da osservazioni, misure e azioni, correlate a fattori e variabili dinamiche negli ordinamenti produttivi”.

Dunque, l'agricoltura di precisione è un sistema di produzione che sfrutta la tecnologia e gli strumenti per eseguire gli interventi agronomici nel posto e nel momento più. Lo scopo di questo tipo di agricoltura è quello di fornire alle piante la quantità di input necessari per crescere in modo ottimale (Ferrari, 2018):

- migliorando la resa agronomica;
- riducendo l'impiego degli input chimici ed energetici.

L'agricoltura di precisione, attraverso una serie di strumentazioni è in grado di monitorare e controllare la variabilità di campo e le condizioni sito specifiche (Bejtja Silva, 2018). Come descritto nelle linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle politiche agricole alimentari e forestali, l'agricoltura di precisione si attesta intorno all'1% della SAU (superficie agricola utilizzata).

1.2.2 Obiettivi e vantaggi dell'agricoltura di precisione

Secondo le linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle politiche agricole alimentari e forestali, gli obiettivi dell'agricoltura di precisione sono quelli di aumentare la produzione agricola, migliorare la qualità e la quantità dei prodotti agroalimentari rispettando i criteri della sostenibilità sia ambientale che climatica.

Lo sviluppo delle tecnologie, in combinazione all'implementazione di software opportuni possono guidare l'agricoltore nella scelta e nella gestione delle attività da svolgere.

Secondo le linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle politiche agricole alimentari e forestali, l'agricoltura di precisione presenta dei benefici economici, climatici ed ambientali, in particolare:

- diminuzione della quantità di acqua utilizzata per l'irrigazione;
- miglioramento dell'efficienza degli input, come ad esempio agrofarmaci e fertilizzanti, con effetti benefici sulla qualità dell'acqua e dell'aria;
- diminuzione dell'ingresso dei composti chimici nelle falde acquifere: *in particolare per l'azoto lisciviato*;
- diminuzione delle attività colturali ed aumento delle rese unitarie: *incremento dell'efficienza*;
- gestione e ripartizione precisa delle risorse idriche, fertilizzanti e fitofarmaci in base all'effettiva esigenza delle colture;
- controllo in real time delle condizioni sanitarie delle colture attraverso l'utilizzo di sensori: es. monitoraggio della comparsa di fitopatogeni;
- fondazione di banche dati al fine di gestire in maniera ottimale le scelte da effettuare.

In seguito, come descritto nelle linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle politiche agricole alimentari e forestali, le tecnologie informatiche che si possono impiegare al servizio dell'agricoltura di precisione (e per beneficiare di tutti i vantaggi citati in precedenza) sono essenzialmente la strumentazione per il campionamento del suolo, i sistemi di guida assistita, i sensori avanzati per l'acquisizione di dati da implementare nella banca dati, le tecnologie IoT (*Internet of Things*), i sistemi di visione artificiale, le applicazioni a rateo variabile per fitofarmaci e concimi. Tra le tecnologie utilizzabili possiamo annoverare anche l'utilizzo di sensori remoti: immagini fornite da satelliti e droni.

Tutto ciò può consentire all'agricoltore di prendere più facilmente le decisioni relative alla gestione aziendale (Bejtja Silva, 2018).

1.3 I droni

1.3.1 Regolamento droni

Nel Regolamento “Mezzi Aerei a Pilotaggio Remoto”, Edizione 3, Emendamento 1 del 14 luglio 2020, l’articolo 743 del Codice della Navigazione “*Nozione di aeromobile*” prevede la definizione di aeromobile: “*Per aeromobile si intende ogni macchina destinata al trasporto per aria di persone o cose. Sono altresì considerati aeromobili i mezzi aerei a pilotaggio remoto, definiti come tali dalle leggi speciali, dai regolamenti dell’ENAC e, per quelli militari, dai decreti del Ministero della Difesa. Le distinzioni degli aeromobili, secondo le loro caratteristiche tecniche e secondo il loro impiego, sono stabilite dall’ENAC con propri regolamenti e, comunque, dalla normativa speciale in materia*”.

In particolare, un aeromobile a pilotaggio remoto (APR), noto comunemente come drone, è definito come un mezzo aereo contraddistinto dall’assenza del pilota a bordo.

Il pilota da remoto è il soggetto responsabile che conduce il volo degli APR:

- se l’APR non è in volo automatico: gestisce manualmente i comandi di volo;
- se l’APR è in volo automatico: gestisce il percorso mantenendosi in grado di prendere provvedimenti in qualunque circostanza.

Nell’Art. 6, la “Classificazione degli APR”, gli APR di competenza ENAC si suddividono in base alla massa operativa al decollo:

- a) mezzi aerei: < 25 kg;
- b) mezzi aerei: \geq 25 kg.

Sempre il Regolamento “Mezzi Aerei a Pilotaggio Remoto”, Edizione 3, Emendamento 1 del 14 luglio 2020 del Codice della Navigazione, suddivide i mezzi aerei in:

- Sistemi aeromobili a Pilotaggio Remoto (SAPR): “sistema costituito da un aeromobile a pilotaggio remoto senza persone a bordo e dai relativi componenti necessari per il controllo e comando (stazione di controllo) da parte di un pilota remoto”.
- Aeromodelli: “dispositivo aereo a pilotaggio remoto, senza persone a bordo, impiegato esclusivamente nell’ambito di organizzazioni legalmente riconosciute costituite in uno Stato Membro esclusivamente per scopi ludico e sportivi, non dotato di equipaggiamenti che ne permettano un volo automatico e/o autonomo, e che vola sotto il controllo visivo diretto e costante dell’aeromodellista, senza l’ausilio di aiuti visivi”.

Inoltre, i droni possono essere così suddivisi:

- struttura ad elica: sono distinti dalla presenza di eliche che conferiscono al mezzo stabilità, dalla capacità di restare fermi in aria e muoversi verticalmente come un elicottero. In particolare questi tipi di droni sono dotati di specifici movimenti:
 - beccheggio: movimento oscillatorio al proprio asse trasversale;
 - imbardata: movimento rotatorio intorno al suo asse verticale baricentrico;
 - rollio: movimento oscillatorio al proprio asse longitudinale;
- struttura planare: a differenza del primo ha un’autonomia maggiore a discapito di una minore manovrabilità;
- struttura ibrida: in grado di muoversi e di spostarsi anche sul terreno grazie alla presenza di due/quattro ruote motrici.

1.3.2 Impiego dei SAPR

Nell'Art. 7, "Impiego dei SAPR", nel Regolamento "Mezzi Aerei a Pilotaggio Remoto", Edizione 3, Emendamento 1 del 14 luglio 2020 del Codice della Navigazione, i SAPR possono essere adoperati per:

- operazioni specializzate in contesti non critici e critici;
- la ricerca e lo sviluppo;
- attività non specializzata in contesti non critici.

In particolare, i droni sono utilizzati prevalentemente per (Di Lucia, 2016):

- servizi militari;
- vigilanza di determinati ambienti;
- servizi civili: ad esempio monitoraggio e controllo del territorio per incendi in corso.

Allo stesso tempo i droni possono essere impiegati in tanti altri contesti disciplinari, tra cui (Di Lucia, 2016):

- conservazione e controllo degli ecosistemi;
- monitoraggio della fauna selvatica: in particolare migrazioni di cinghiali che arrecano danni alle colture;
- controlli antibraconaggio;
- individuazione e riconoscimento delle specie;
- applicazioni in agricoltura.

1.4 Utilizzo dei droni in agricoltura

Negli ultimi anni sono stati sviluppati dei sensori che possono essere montati anche sugli APR di ridotte dimensioni, i quali sono in grado di effettuare voli su qualsiasi coltura (Bietresato, 2018).

Nell'agricoltura di precisione, l'integrazione di determinati sensori sui droni e tutti i dati ottenuti, forniscono all'agricoltore informazioni utili sullo stato del terreno e delle colture.

I dati, attinti dai sensori installati dai droni, possono essere rielaborati in modo da ottenere (Bietresato, 2018):

- ortofoto: ottenute da singole foto;
- mappe di prescrizione: mappe georeferenziate che servono per analizzare lo stato delle colture;
- modelli tridimensionali: nuvole di punti 3D.

La ricerca e lo sviluppo di nuovi metodi di elaborazione dei dati sono indispensabili per estrarre il maggior numero di informazioni per l'analisi dei risultati che possono permettere all'agricoltore di pianificare interventi specifici al momento giusto riducendo al massimo la quantità di input (Bietresato, 2018). Gli input tecnici che possono essere ottimizzati sono in particolare i fitofarmaci, i fertilizzanti, i diserbanti, il carburante, le risorse idriche (Bietresato, 2018).

1.4.1 Sensoristica

Generalmente, i sensori che possono essere montati sui droni nell'ambito dell'agricoltura sono i seguenti (Minucci, 2018):

- sensori RGB;
- sensori multispettrali;
- sensori iperspettrali;
- sensori termici;
- sensori LiDAR.

1.4.1.1 Sensori RGB

Nelle operazioni di rilievo fotogrammetrico si impiegano solitamente dei sensori ottici costituiti da fotocamere digitali RGB. L'acronimo RGB (*Red, Green and Blue*) identifica le tre tonalità di colore: rosso, verde e blu. Lo spettro sensibile dei sensori RGB coincide con lo spettro elettromagnetico del visibile, indicativamente tra i 380 ai 750 nm. Questo dispositivo ottico permette di trasformare una sorgente luminosa, e perciò le immagini, in un segnale elettrico. Le immagini ottenute vengono convertite e processate dalla fotocamera, misurando le componenti RGB di ciascun pixel in maniera tale da rendere compatibile i dati dell'immagine con i software di visualizzazione (formati JPEGG e TIFF). Per ricavare un'immagine accurata dal punto di vista cromatico, ogni pixel annotato deve racchiudere le informazioni cromatiche di tutte le componenti RGB della luce incidente su ogni pixel. Dunque, l'informazione è data dalla sovrapposizione dei tre colori RGB (Minucci, 2018).

1.4.1.2 Sensori multispettrali

Il sensore multispettrale può rilevare la radiazione, riflessa da un elemento di natura materiale o emanata da una sorgente luminosa, nelle varie lunghezze d'onda dello spettro elettromagnetico (solitamente spettro visibile e infrarosso), generando immagini multibanda. A differenza dello spettro del visibile, gli infrarossi (in particolare il NIR: *Near infrared*) hanno una lunghezza d'onda compresa tra 750 e 1400 nm (Minucci, 2018). Ogni elemento di natura materiale assorbe e riflette diverse lunghezze d'onda. In particolare la vegetazione assorbe nella banda del rosso e del blue e riflette nella banda del verde e nell'infrarosso. Dunque, la radiazione elettromagnetica dell'infrarosso (NIR) può fornirci informazioni utili riguardo lo stato di salute delle colture. Inoltre, possiamo calcolare indici di vegetazione che combinano immagini ad infrarosso con il visibile, al fine di ricavare con grande accuratezza lo stato delle colture. Nel dettaglio, gli indici di vegetazione possono servire a definire:

- lo stato di salute della coltura che dipende dall'assorbimento e dalla riflessione delle diverse bande dello spettro elettromagnetico (Minucci, 2018);
- stimare lo stato nutrizionale delle piante;
- identificare stress biotici e abiotici;
- stimare la produzione e la resa delle colture (Basso et al, 2011; Li et al, 2014; Marino et al., 2014, 2015).

Per assicurarsi un risultato attendibile dai dati acquisiti è indispensabile utilizzare contemporaneamente diversi indici di vegetazione in quanto ognuno di questi fornisce un'informazione che muta a seconda:

- della specie vegetale;
- delle proprietà chimico-fisiche del suolo;
- del clima.

1.4.1.3 Sensori iperspettrali

Il sensore iperspettrale, a differenza del multispettrale, può ottenere informazioni più dettagliate. Questi dispositivi sono capaci di rilevare la radiazione solare riflessa su un'ampia regione dello spettro, fornendo per ciascun pixel la quasi totalità dello spettro elettromagnetico (Colomina, Molina 2014). Per ciascuna immagine ricavata, ossia ogni pixel, esprime la riflettanza ad una specifica lunghezza d'onda della superficie visibile da quel pixel. Il complesso dei dati iperspettrali è costituito da 100-200 fasce di larghezza di banda più stretta rispetto a quelli ottenuti dai dati multispettrali, i quali sono formati da 5-10 bande relativamente più larghe. Studiando la firma spaziale di un oggetto in specifiche condizioni fisiche è ammissibile identificarlo univocamente (Minucci, 2018).

1.4.1.4 Sensori termici

Lo spettro di azione della radiazione a infrarosso termico è compreso tra 7,5 e 13 μm . L'immagine a infrarosso, riproduce la distribuzione del calore dello spazio ripreso dal sensore a infrarossi. (Meola, Carlomagno 2004).

Il campo spettrale dei sensori termici comprende il:

- VIR: infrarosso vicino al visibile;
- SW: infrarosso ad onda corta;
- MW: infrarosso medio;
- LW: infrarosso lontano;
- XLW: infrarosso verso microonde.

1.4.1.5 Sensori Lidar: *Light Detection and Ranging*

Il sensore LiDAR è una tecnica di telerilevamento che consente di definire lo spazio tra il sensore stesso e un oggetto o superficie impiegando un impulso laser (Historic England 2018 b). Con questa tecnica è possibile ottenere, in breve tempo, informazioni geometriche 3D di molteplici punti dell'area interessata. L'intervallo di spazio tra il sensore e l'oggetto, o superficie, è definito calcolando il tempo che passa tra l'emissione e la ricezione del raggio laser riflesso (Minucci, 2018).

1.5 Rilevamento delle specie vegetali infestanti con l'impiego di droni

Nell'ambito del rilevamento delle specie vegetali infestanti, i droni sono in grado di produrre immagini digitali, le quali hanno un ruolo fondamentale per (Peña et al., 2013):

- la creazione di mappe di prescrizione;
- il monitoraggio delle malerbe;
- la progettazione di trattamenti sito-specifici di diserbanti: *in particolare nella fase di emergenza della coltura di interesse.*

Il controllo sito-specifico delle infestanti porta ad una diminuzione della quantità di diserbante applicata in campo riducendo anche i rischi di inquinamento (Lameski et al., 2018). In particolare, le mappe acquisite tramite drone, possono condurre ad una riduzione dell'impiego di diserbanti fino al (Gerhards & Christensen 2003):

- 60% per le infestanti a foglia larga;
- 90% per le infestanti a foglia stretta:

Loghavi e Mackvandi, (2008), hanno riscontrato che, controllando le infestanti in maniera sito-specifica, vi è un risparmio della quantità di diserbanti di circa il 69,5% rispetto ad un trattamento tradizionale.

De Castro et al., (2012), hanno usufruito di immagini multispettrali per discriminare le infestanti in campi di Brassicaceae utilizzando metodi di apprendimento automatico e indici di vegetazione risparmiando sulla quantità di diserbante impiegato:

- per le aree non trattate: dal 71,7% al 95,4%;
- per le aree a basso dosaggio: dal 4,3% al 12%.

1.6 Problematiche delle malerbe

“Con il termine di *pianta infestante*, oppure *malerba* o, popolarmente *erbaccia*, si intende generalmente una pianta che, non rivestendo alcuna funzione utile per l’uomo, ne va a danneggiare le produzioni agricole entrando in competizione o parassitizzando queste ultime. Tuttavia, in senso più ampio e completo, il concetto può essere esteso, oltre che alle piante infestanti i campi coltivati, anche a quelle che crescendo in ambienti sia antropizzati che naturali, interferiscono con le attività dell’uomo o modificano gli ecosistemi” (Vurro et al., 2008).

Nei sistemi agricoli, le specie vegetali infestanti sono un fattore limitante per le colture agricole, poiché competono per diverse risorse tra cui radiazione solare, spazio, acqua e sostanza nutritive (Nieto et al 1968, Zimdahl 1980).

La presenza delle specie infestanti nei campi coltivati causa notevoli perdite economiche, le quali sono state misurate su scala mondiale:

- con l’utilizzo di mezzi per il controllo delle malerbe: 13% (Zoeschke e Quadranti, 2002);
- senza l’utilizzo di provvedimenti per il contenimento delle malerbe: intorno al 34% (Oerke, 2006).

Invece, per quanto riguarda le colture in Italia, le perdite economiche si attestano (Zanin et al., 1992):

- nel frumento: 23-30%;
- nel mais: 34-37%;
- nella soia: 33%;
- nella bietola: 50%;
- nel riso: oltre il 50% (Vidotto e Ferrero, 2009).

Con questi presupposti, una corretta gestione delle specie infestanti è alla base di un’agricoltura economicamente sostenibile (Zanin et al., 1992).

1.7 Procedure e problematiche per il rilevamento delle piante infestanti a partire da immagini acquisite da drone

Negli ultimi anni, le tecnologie informatiche abbinate ai sistemi di visione artificiale, ossia dispositivi e tecniche in grado di acquisire e rielaborare immagini per ottenere informazioni, sono diventate degli strumenti che sono in grado di rilevare in maniera accurata sia le colture di interesse che le specie vegetali infestanti, ricavando informazioni importanti per una corretta gestione sito-specifica delle malerbe (Meyer et al., 1998; Onyango e Marchant, 2003; Søgaaard, 2005; Schuster et al., 2007). In concreto, le immagini che sono state ottenute tramite SAPR vengono fornite come input al sistema informatico per essere rielaborate (Wang et al., 2019).

Le procedure di rielaborazione delle immagini sono le seguenti:

- a. pre-processing: *pre-elaborazione*;
- b. vegetation segmentation: *segmentazione della vegetazione*;
- c. feature extraction: *estrazione delle caratteristiche*;
- d. classification: *classificazione* (Weis e Sökefeld, 2010).

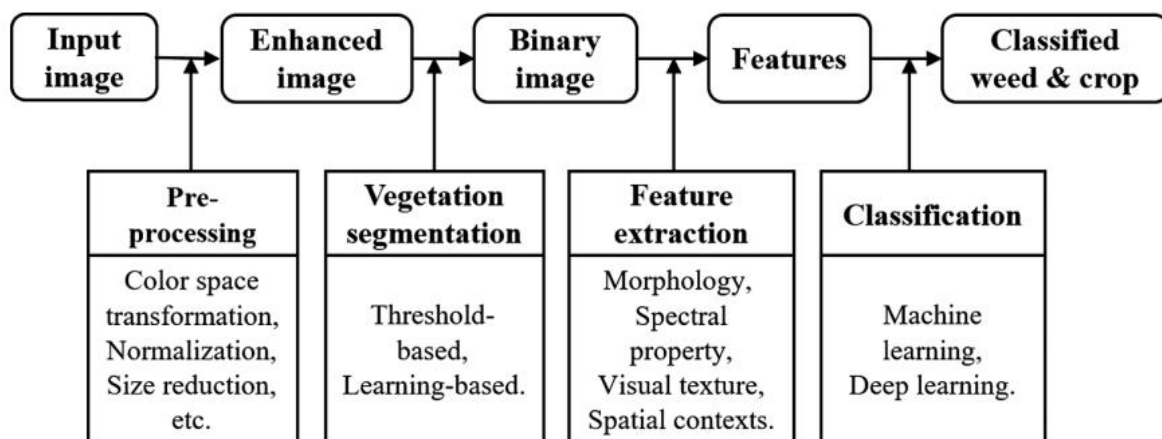


Figura 1.7: Procedure di rielaborazione delle immagini per il rilevamento delle specie vegetali (Wang et al., 2019).

1.8 Pre-processing: *pre-elaborazione*

Le immagini originali possono essere pre-elaborate per migliorare la qualità del risultato finale.

Le operazioni di pre-elaborazioni si possono suddividere in (Wang et al., 2019):

- scelta dello spazio colore;
- denoising;
- miglioramento del contrasto;
- normalizzazione dell'immagine;
- ridimensionamento dell'immagine.

1.8.1 Spazio colore

Per il rilevamento delle specie vegetali possono essere impiegati diversi modelli di spazio colore. I più usati sono (Cheng et al., 2001):

- RGB (Red Green Blue): *modello basato sulla somma dei colori rosso, verde e blu*;
- HSB (Hue Saturation Brightness) o HSV (Hue Saturation Value) o HSI (Hue Saturation Intensity): *tonalità, saturazione e luminosità*;
- YCrCb: *dove Y rappresenta la luminanza, Cr e Cb indicano la cromaticità*.

Ogni modello può essere convertito in un altro tramite apposite funzioni di trasformazione. Generalmente il modello RGB è quello più utilizzato poiché è specificatamente adatto nel rappresentare e visualizzare le immagini a colori. Tuttavia, non è particolarmente adatto per la segmentazione delle immagini a causa dell'elevata correlazione tra le componenti del modello stesso (RGB) (Cheng et al., 2001). Per questo motivo, alcuni ricercatori convertono il modello RGB in altri tipi di modello (Wang et al., 2019):

- modello YCrCb: è stato impiegato per identificare la vegetazione in diverse condizioni di illuminazione, in particolare quando, nell'immagine, la componente verde prevale sulla componente rossa e blu (Tang et al., 2016).
- modello HSV: anche questo modello non è sensibile alla variazione di luce, ma rispetto al modello precedente (*YCrCb*) è più adatto alla percezione visiva dell'occhio umano (Hamuda et al., 2017).

1.8.2 Denoising

Il “rumore digitale” è un segnale di disturbo che si manifesta generalmente nelle immagini realizzate in ambienti con scarsa luminosità. Questo difetto rende difficile la fase di segmentazione e le operazioni successive. Tuttavia, per migliorare la qualità dell’immagine originale e ridurre l’effetto “noise”, è sufficiente utilizzare specifici filtri, che si adattano bene al contesto (Wang et al., 2019).

1.8.3 Contrasto

Nelle immagini digitali, il contrasto è la differenza di illuminazione tra le regioni illuminate e quelle ombreggiate. Attraverso un miglioramento del contrasto è possibile modificare le immagini ottenute in condizioni di scarsa luminosità e in presenza di ombre (Jeon, 2014). Il contrasto può essere corretto attraverso la regolazione del livello del grigio (Liu et al., 2014). Le immagini, ottenute da camere multispettrali, possono essere combinate per regolare il contrasto e per separare meglio la vegetazione dal suolo (Li et al., 2013).

1.8.4 Normalizzazione dell’immagine

Attraverso l’equalizzazione dell’istogramma è possibile calibrare il contrasto e le variazioni di illuminazione (Siddiqi e Seok-Won Lee, 2014).

1.8.5 Ridimensionamento dell’immagine

Il ridimensionamento delle immagini è opportuno per ridurre (Tang et al., 2018):

- la risoluzione delle immagini;
- le operazioni e i costi di calcolo.

1.9 Vegetation segmentation: *segmentazione della vegetazione*

Nell'elaborazione digitale delle immagini, la segmentazione consiste in un processo per raggruppare una determinata quantità di pixel per creare oggetti con proprietà relativamente analoghe (Ashok Kumar e Prema, 2013; Hamuda et al., 2016).

Nel caso del rilevamento delle infestanti, la segmentazione è indispensabile per separare le due classi (Hamuda et al., 2016):

- vegetazione: *coltura di interesse e le specie infestanti*;
- sfondo: *suolo e residui vegetali*.

La rimozione dello sfondo è una delle operazioni più critiche per il rilevamento delle infestanti (Ashok Kumar e Prema, 2013; Sabzi et al., 2018) e deve essere svolta in maniera efficace per evitare di classificare erroneamente una specie vegetale.

In questo ambito, i metodi per segmentare le immagini sono (Hamuda et al., 2016):

- segmentazione basata sull'indice di colore;
- segmentazione basata su soglia;
- segmentazione basata sull'apprendimento.

1.9.1 Segmentazione basata sull'indice di colore

Generalmente, la caratteristica del colore è il metodo più utilizzato per identificare e discernere la vegetazione dallo sfondo. Alcuni studiosi hanno utilizzato l'indice di colore non solo per distinguere le piante dal suolo e dai residui, ma anche per stimare l'indice di area fogliare (LAI) (Rasmussen et al., 2007; Meyer and Camargo-Neto, 2008; Kirk et al., 2009). Gli indici di colore più utilizzati sono:

- **Normalised Difference Index: *NDI***

Questo indice è stato proposto da Woebbecke et al. (1992), il quale produce un'immagine quasi binaria.

Vantaggi:

- semplice da calcolare;
- resistente a diversi gradi di illuminazione.

Svantaggi:

- non funziona bene in condizioni di scarsa ed eccessiva illuminazione;
- produzione di falsi positivi.

- **Excess Green Index: *ExG***

Secondo Woebbecke et al., (2015), dopo aver utilizzato diversi indici di colore, il metodo migliore per distinguere la vegetazione dal suolo è l'indice "Excess Green", poiché è in grado di fornire un contrasto netto tra le piante e il suolo producendo quasi immagini binarie. "Excess Green Index" è stato ampiamente utilizzato e ha ottenuto ottimi risultati nella separazione delle piante dallo sfondo" (Meyer et al., 1998; Lamm et al., 2002; Ribeiro et al., 2005; Guerrero et al., 2012).

Vantaggi:

- facile da calcolare;
- si adatta bene all'ambiente esterno.

Svantaggi:

- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

- Excess Red Index: *ExR*

Anche questo indice, introdotto da Meyer et al. (1998), ha prodotto risultati accurati, ma non quanto l'indice ExG.

Vantaggi:

- facile da calcolare;
- anche se si basa solo sulla componente in rosso è in grado di estrarre i pixel verdi.

Svantaggi:

- non è accurato quanto ExG;
- non funziona bene in condizioni di scarsa od eccessiva illuminazione.

- Colour Index of Vegetation Extraction: *CIVE*

Questo indice è stato presentato da Kataoka et al. (2003) in uno studio su campi di soia. Questo criterio è stato utilizzato per stimare le diverse fasi di sviluppo delle colture.

Vantaggi:

- breve tempo di esecuzione;
- buona adattabilità all'ambiente esterno.

Svantaggi:

- funziona male in condizioni di scarsa ed eccessiva illuminazione;
- non si presta in condizioni di eccessivo ombreggiamento.

- Excess Green minus Excess Red Index: *ExGR*

Questo metodo, presentato da Meyer et al. (2004), è possibile ricavarlo dalla combinazione di due indici di colore: ExG e ExR.

Entrambi gli indici sono stati impiegati contemporaneamente per discernere la vegetazione dallo sfondo con:

- ExG: utilizzato per estrarre i pixel verdi e quindi separare la vegetazione;
- ExR: usato per rimuovere lo sfondo.

Vantaggi:

- buona adattabilità in ambienti esterni.

Svantaggi:

- segmenta il pixel dell'ombra come vegetazione;
- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

- Normalised Green-Red Difference Index: *NGRDI*

Introdotta da Hunt et al. (2005).

Vantaggi:

- costituito da due componenti:
 - I. componente: utilizzato nella discriminazione tra la vegetazione e il suolo;
 - II. componente: utile nell'equilibrare la variazione di luce in immagini differenti.

Svantaggi:

- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

- Vegetative Index: *VEG*

Proposto da Hague et al. (2006).

Vantaggi:

- robusto alla variazione di illuminazione.

Svantaggi:

- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

- Combined Indices 1: *COMI*

Introdotta da Guijarro et al. (2011), ed è costituito dalla combinazione di più indici: ExG, ExGR, CIVE e VEG.

Vantaggi:

- buona adattabilità in ambienti esterni.

Svantaggi:

- incremento del tempo di calcolo;
- non funziona bene in condizioni di scarsa ed eccessiva illuminazione;
- non si presta in condizioni di eccessiva ombra: *sovrapposizione come nell'indice CIVE*.

- Modified Excess Green Index: *MExG*

Proposto da Burgos-Artizzu et al. (2011).

Vantaggi:

- buona adattabilità in ambienti esterni.

Svantaggi:

- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

- Combined Indices 2: COM2

Introdotta da Guerrero et al. (2012), ed è composta da diversi indici: *ExG*, *CIVE* e *VEG*.

Vantaggi:

- buona adattabilità in ambienti esterni.

Svantaggi:

- incremento del tempo di calcolo;
- non funziona bene in condizioni di scarsa ed eccessiva illuminazione.

1.9.1.1 Considerazioni generali sulla segmentazione basata sugli indici di colore

Questo approccio è stato impiegato da diversi studiosi per valutare la capacità degli indici nell'estrazione della vegetazione e per affinarne la qualità di segmentazione in diverse condizioni ambientali (Hamuda et al., 2016).

Durante la crescita della vegetazione, la caratteristica che rimane quasi invariata è il colore. Al contrario, altre caratteristiche, come la dimensione e l'orientamento spaziale della vegetazione, variano nel tempo rendendole inappropriate per l'operazione di segmentazione. Per questo motivo molti ricercatori ricorrono a questo tipo di criterio (Bai et al., 2014).

In generale, questo metodo ha dimostrato di essere abbastanza robusto nella separazione tra la vegetazione e il suolo in ambienti complessi e in diverse condizioni di illuminazione. Tuttavia, questi indici non si prestano bene a tutti gli scenari di segmentazione, soprattutto in ambienti con scarsa od eccessiva illuminazione (Hamuda et al., 2016).

1.9.2 Segmentazione basata su soglia

In questo metodo, in un'immagine in scala di grigio, ciascun pixel può appartenere a due o più classi, in base al superamento o meno di soglie predefinite:

- “pixel vegetale”: se il valore dell'intensità del pixel supera una certa soglia prefissata;
- “pixel di sfondo”: se il valore non supera quella determinata soglia (Hassanein et al., 2018; Kaur e Kaur, 2014).

Le immagini in scala di grigio sono ottenute attraverso una conversione a partire da immagini RGB (Hamuda et al., 2016). Il punto critico di questo approccio è la determinazione di corretti valori soglia, per evitare:

- sotto-segmentazione: valore di soglia troppo alto, in cui alcune regioni, appartenenti alla vegetazione, possono essere raggruppate nelle regioni dello sfondo.
- sovra-segmentazione: valore di soglia troppo basso, in cui alcune “regioni di sfondo” possono fondersi con le “regioni di vegetazione” (Hamuda et al., 2016).

Dunque, diversi studiosi hanno cercato di risolvere questo metodo attraverso l'implementazione di diverse tecniche (Hamuda et al., 2016). Le tecniche più utilizzate in questo approccio sono:

- **Dynamic threshold**

Questo metodo è stato introdotto da Reid and Searcy (1987), dove ogni immagine viene suddivisa in diverse sotto-immagini, e successivamente viene scelta una soglia per ogni sotto-immagine.

Vantaggi:

- resistente alla variazione graduale dell'illuminazione;
- resistente all'ombreggiatura.

Svantaggi:

- incremento del tempo di calcolo.

- Hysteresis threshold

Questo metodo è stato proposto da Marchant et al. (1998), ed è composto da due soglie: una alta e una bassa. Ciò comporta alla creazione di tre classi:

- valori al di sotto della soglia bassa: vengono rimossi;
- valori tra le due soglie: vengono mantenuti solo se associati ad un pixel sopra la soglia alta;
- valori al di sopra della soglia alta: vengono mantenuti.

Vantaggi:

- maggiore accuratezza di segmentazione.

Svantaggi:

- incremento del tempo di calcolo.

- Fixed threshold:

L'utilizzo della soglia fissa, introdotta da Hemming e Rath (2001) e Aitkenhead et al. (2003), è stata ampiamente utilizzata da diversi ricercatori.

Vantaggi:

- semplice.

Svantaggi:

- vulnerabile alle variazioni di illuminazione;
- adatto solo in condizioni specifiche (Sabzi et al., 2018).

- Automatic threshold

Proposto da Kirk et al. (2009).

Vantaggi:

- tecnica automatica;

Svantaggi:

- incremento del tempo di calcolo.

- Otsu threshold

Questa tecnica, proposta da Otsu (1979), è stata impiegata da diversi ricercatori per diverse applicazioni di segmentazione.

In particolare, Shrestha et al. (2004) e Ling e Ruzhitsky in (1996), hanno applicato questo metodo per segmentare la vegetazione dallo sfondo.

Secondo Sahoo et al. (1988), rispetto ad altre tecniche basate sulla soglia, la soglia di Otsu è il metodo che fornisce i valori più accurati.

Vantaggi:

- tecnica automatica.

Svantaggi:

- a volte produce sotto-segmentazione;
- metodo abbastanza lento.

- Homogeneity threshold

Gebhardt et al. (2006) e Gebhardt e Kaühbauch (2007) hanno convertito immagini RGB in immagini in scala di grigio in modo tale da misurare l'omogeneità locale delle immagini ricavandone un valore soglia di omogeneità per derivare immagini binarie.

Vantaggi:

- utile nel rilevare piccole zone;
- resistente alle variazioni di illuminazione.

Svantaggi:

- incremento del tempo di calcolo.

1.9.3 Segmentazione basata sull'apprendimento

In specifiche condizioni di illuminazione o di presenza di nuvole, la segmentazione basata sull'indice di colore non ha sempre fornito risultati soddisfacenti (Hamuda et al., 2016). Per questo motivo, alcuni ricercatori hanno provato a utilizzare un nuovo tipo di metodo, detto “approccio basato sull'apprendimento”, il quale, rispetto anche alla segmentazione basata sulla soglia, è in grado di segmentare la vegetazione dallo sfondo in maniera più accurata (Wang et al., 2019).

Nel dettaglio, questo tipo di tecnica prevede l'addestramento delle proprietà comuni degli oggetti, presenti nell'immagine, attraverso l'utilizzo di algoritmi di apprendimento automatico, dove ciascun pixel viene contrassegnato ad una specifica categoria (Wang et al., 2019).

Questo metodo si può suddividere in due classi (Hamuda et al., 2016):

- approccio supervisionato;
- approccio non supervisionato.

1.9.3.1 Approccio supervisionato

In questo tipo di tecnica si ricorre ad un processo di addestramento per definire un modello di classificazione, dove le immagini, precedentemente annotate, devono essere assegnate come campioni di addestramento (Wang et al., 2019). Questo approccio si presta bene quando le immagini acquisite da segmentare hanno proprietà simili ai campioni di addestramento. Inoltre, maggiore è la quantità dei campioni di addestramento, maggiore sarà la prestazione di questo metodo (Wang et al., 2019).

Di seguito, alcune tecniche basate sull'apprendimento supervisionato:

- Metodo EASA: *Environmentally Adaptive Segmentation Algorithm*

Tian e Slaughter (1998) hanno applicato questa tecnica su immagini RGB con il compito di rilevare le piante.

Vantaggi:

- si presta soprattutto nelle ore soleggiate su campi all'aperto.

Svantaggi:

- solo circa il 45-50% di tutte le piante sono state rilevate in presenza di nuvole;
- richiede diversi campioni di addestramento per produrre risultati precisi.

Ruiz-Ruiz et al. (2009), si è servito di immagini HSB (*Hue saturation Brightness*) per generare una solida segmentazione della vegetazione in condizioni di campo complesse.

Vantaggi:

- tempo di calcolo: *ridotto*;
- resistente in diverse condizioni di illuminazione.

Svantaggi:

- non è adatto nei primi stadi di crescita delle piante.

- Metodo MS-BPNN: *Mean-shift algorithm with Back Propagation Neural Network*

Zheng et al. (2009) ha proposto un algoritmo utilizzando lo spazio colore RGB e HSI.

Vantaggi:

- resistente in diverse condizioni di illuminazione.

Svantaggi:

- tempi di calcolo: aumentati;
- bassa segmentazione in piante o parti di vegetazione in zone ombreggiate.

- Metodo MS-FLD: *Mean-shift algorithm with Fisher Linear Discriminant*

Per segmentare le parti verdi della vegetazione ombreggiate, Zheng et al. (2010), ha utilizzato la Discriminante Lineare di Fisher.

Vantaggi:

- buona segmentazione in piante o parti di vegetazione in zone ombreggiate.

Svantaggi:

- tempo di calcolo: lunghi.

- Metodo SVM: *Support Vector Machines*

Guerrero et al., (2012) ha proposto un metodo di apprendimento per segmentare:

- regioni mascherate: suolo e altri materiali;
- regioni non mascherate: vegetazione.

Viene utilizzato lo spazio di colore RGB.

Vantaggi:

- identifica la vegetazione nel caso in cui parti di essa sono contaminate da altri materiali.

Svantaggi:

- tempo di calcolo: aumentato.

- Metodo DTSM: *Decision Tree based Segmentation Model*

Metodo adottato da Guo et al. (2013) per risolvere problemi di scarsa illuminazione e parti di regioni che riflettono la luce, in immagini RGB.

Vantaggi:

- identifica la vegetazione nel caso in cui parti di essa sono ombreggiate o riflettono luce.

Svantaggi:

- dipendente dai campioni di addestramento.

- Metodo CNN: *Convolutional Neural network*, introdotto da Potena et al., (2017).

1.9.3.2 Approccio non supervisionato

In questa tecnica, a differenza di quella precedente, non è indispensabile annotare le immagini.

I metodi più utilizzati sono i seguenti:

- **Metodo FC:** *Fuzzy Clustering*

Meyer et al. (2004) propone di utilizzare questo metodo per estrarre la regione di interesse da immagini ExG e ExR a partire dallo spazio colore RGB.

Vantaggi:

- segmentazione accurata.

Svantaggi:

- se nell'immagine la regione di vegetazione in pixel è inferiore al 10%, la tecnica non è in grado di raggruppare i pixel con proprietà simili a causa della scarsa quantità di dati.

- **Metodo PSO-MM:** *Particle Swarm Optimisation clustering and Morphology Modelling*

Vantaggi:

- lavora bene in condizioni variabili di illuminazione.

Svantaggi:

- tempi di calcolo: lunghi, dipende da diverse fasi di elaborazione.

1.9.3.3 Miglioramento dell'immagine segmentata

A questo punto, l'immagine può ancora essere migliorata in quanto può contenere:

- errori di classificazione dei pixel;
- “rumori digitali”;
- raggruppamenti indesiderati tra regioni diverse.

In questo caso, possono essere adottate delle misure per affinare la qualità dell'immagine.

Le misure utilizzate più frequentemente sono le due seguenti operazioni:

- apertura morfologica: il contorno degli oggetti viene levigato e rifinito più accuratamente.
- chiusura morfologica: i piccoli spazi vuoti, presenti all'interno delle regioni, vengono riempiti (Ahmed et al., 2012).

Inoltre, è possibile utilizzare metodi di filtraggio, come il filtro mediano, per eliminare il “rumore digitale” dalle immagini (Aware and Joshi, 2015; Kazmi et al., 2015).

1.10 Considerazione sugli approcci elencati

Tabella 1.10a: complessità, performance in real-time e livello di accuratezza per ogni tipo di segmentazione. Rivisitazione della “table 4” di Hamuda et al., (2016).

Tipo di segmentazione	Complessità	Real-time performance	Accuratezza
Indice di colore	Semplice	Efficace	Bassa precisione in caso di scarsa o eccessiva illuminazione
Soglia	Relativamente semplice	Piuttosto efficace	Media accuratezza
Apprendimento	Complesso	Costoso	Molto accurato

Tabella 1.10b: algoritmi di segmentazione suggeriti in differenti condizioni ambientali. Rivisitazione della “table 4” di Hamuda et al., (2016).

Tipo di segmentazione	Stato del cielo e qualità dei risultati		
	Nuvoloso	Coperto	Soleggiato
Indice di colore	Efficace	Risultati scadenti	Risultati scadenti
<i>Algoritmi suggeriti</i>	- CIVE, COM1	- CIVE, ExGR	- ExG, COM2
Soglia	Efficace	Modifiche necessarie	Modifiche necessarie
<i>Algoritmi suggeriti</i>	- Otsu	- Dynamic threshold - Homogeneity threshold	- DT - HT
Apprendimento	Efficace	Necessari diversi step di addestramento	Necessari diversi step di addestramento
<i>Algoritmi suggeriti</i>	- EASA	- AP-HI	- DTSM

1.11 Estrazione delle caratteristiche

La fase di segmentazione è necessaria per estrarre, dalle immagini originali, le specie vegetali dallo sfondo (Wang et al., 2019). Tuttavia, la coltura di riferimento e le malerbe sono ancora fuse insieme. Pertanto, sono state adottate diverse tecniche per discriminare le specie vegetali, le quali possono essere classificate in quattro categorie (Slaughter et al., 2008; Slaughter, 2013; Weis e Sökefeld, 2010):

- a. morfologia biologica;
- b. caratteristiche spettrali;
- c. analisi della texture;
- d. contesti spaziali.

1.11.1 Morfologia biologica

Le proprietà morfologiche, in particolare la forma e la struttura di una pianta, possono essere sfruttate per analizzare le immagini e per rilevare le specie vegetali (Slaughter et al., 2008; Weis e Sökefeld, 2010). Le caratteristiche morfologiche si possono suddividere in (Brown e Noble, 2005):

- misurazione della forma basata sulla regione;
- parametri di forma basati sulla regione;
- fattori di forma basati sui limiti.

- Misurazione della forma basata sulla regione

Le caratteristiche della forma si basano sulla misurazione delle zone annotate. In particolare, possiamo trovare: perimetro, diametro, lunghezza dell'asse minore o maggiore e l'area (Herrera et al. 2014; Mathanker et al. 2010).

- Parametri di forma basati sulla regione

Questi indici sono una combinazione di almeno due misurazioni di forma, tra cui eccentricità, circolarità, convessità e solidità. Questi parametri sono valori numerici adimensionali e indipendenti da (Bakhshipour e Jafari, 2018):

- geolocalizzazione;
- traslazione;
- scala di rappresentazione.

- Fattori di forma basati sui limiti

Questa caratteristica fornisce informazioni in relazione ai contorni delle zone annotate. I descrittori di forma sono generalmente più complessi rispetto alle altre due caratteristiche morfologiche e richiedono operazioni complicate. I fattori di forma sono:

- Moment Invariants (MI): (Bakhshipour e Jafari, 2018; Ming-Kuei Hu, 1962);
- Fourier Descriptor (FD): (Pereira et al., 2012);
- Beam Angle Statistics (BAS): (Pereira et al., 2012);
- Tensor Scale Descriptor (TSD): (Pereira et al., 2012).

Le proprietà morfologiche, elencate precedentemente, si utilizzano in condizioni ordinarie. Tuttavia, non si adattano bene in casi di immagini occluse, sovrapposizione e danneggiamento delle foglie delle specie vegetali, generando risultati insoddisfacenti (Wang et al., 2019).

1.11.2 Caratteristiche spettrali

Le caratteristiche spettrali, soprattutto gli indici di colore, sono in grado di fornire risultati apprezzabili per la segmentazione delle specie vegetali. Nel contempo sono efficaci anche per discriminare le piante quando esse presentano un diverso colore delle foglie. Tuttavia, quando le piante presentano un colore simile, le caratteristiche spettrali non forniscono risultati accettabili. Le caratteristiche spettrali maggiormente utilizzate per la discriminazione della vegetazione sono:

- Normalized different vegetation index: *NDVI*, (Hao et al., 2015);
- Mean Red Average red value inside a window: (Cheng and Matson, 2015);
- Mean Green Average green value in an image: (Mathanker et al., 2010);
- *CVI2: ExG, GB*, (Kazmi et al., 2015).

Le caratteristiche spettrali, rispetto alle caratteristiche morfologiche, sono:

- meno sensibili alle parziali occlusioni delle immagini;
- tempi di calcolo per l'ottenimento dei risultati sono ridotti.

Tuttavia, le caratteristiche morfologiche sono più efficaci per discriminare correttamente le specie vegetali (Slaughter et al., 2008). Pertanto, le caratteristiche basate sullo spettro e sulla morfologia sono spesso combinate per ottenere risultati soddisfacenti (Ahmed et al., 2012). Negli ultimi anni, alcuni ricercatori stanno sperimentando l'utilizzo di sensori iperspettrali per la discriminazione della coltura di riferimento dalle specie vegetali infestanti ma sono necessarie ulteriori ricerche (AlSuwaidi et al., 2016; Herrmann et al., 2013).

1.11.3 Analisi della texture

Questa tecnica è stata ampiamente utilizzata da diversi ricercatori per identificare regioni di interesse e ricavarne informazioni utili. Per texture si intende una qualsiasi disposizione spaziale e/o ripetitiva dei livelli di grigio in un'immagine digitale.

Le texture descrivono caratteristiche come:

- ruvidità/levigatezza;
- grossolanità;
- regolarità (Bakhshipour et al., 2017; Bharati et al., 2004; Gonzalez e Woods, 2007).

Questo metodo può suddividersi in quattro categorie:

- caratteristiche statistiche: (Haralick et al., 1973);
- caratteristiche strutturali: (Bharati et al., 2004; Materka e Strzelecki, 1998);
- caratteristiche basate sul modello: (Materka e Strzelecki, 1998; Zhang e Tan, 2002);
- caratteristiche basate sulla trasformazione: (Materka e Strzelecki, 1998; Prema e Murugan, 2016).

1.11.4 Contesti spaziali

Le caratteristiche morfologiche e spettrali sono sensibili alle variazioni nell'aspetto della pianta, in particolare durante il loro stadio di crescita, producendo risultati insoddisfacenti. Al contrario, la geolocalizzazione delle piante seminate in fila può aiutare a migliorare la discriminazione tra le specie vegetali (Midtiby et al., 2016). Le colture, in particolare i cereali come il frumento e l'orzo, che vengono seminate in fila, hanno il problema delle specie infestanti che sorgono tra le file. Tuttavia, tutte le piante che si trovano tra le due file possono essere classificate come specie vegetali infestanti (Wang et al., 2019).

1.12 Classificazione

L'ultima operazione consiste nel classificare le differenti specie vegetali. La classificazione tra la coltura di interesse e le malerbe possono essere suddivise in:

- classificazione basata sul machine learning;
- classificazione basata sul deep learning.

1.12.1 Classificazione basata sul machine learning

Generalmente, questo tipo di apprendimento attiene alle procedure precedentemente elencate: pre-elaborazione, segmentazione, estrazione delle caratteristiche e classificazione. Nel campo dell'informatica, il machine learning, o apprendimento automatico, è una branca dell'Artificial Intelligence (AI), nella quale in una macchina intelligente si introduce la capacità di apprendere autonomamente le informazioni dai dati senza la programmazione di regole esplicite (Singh et al., 2016, De Mauro, 2019, Bishop, 2006). Il machine learning può essere suddiviso in:

- apprendimento non supervisionato;
- apprendimento supervisionato.

1.12.1.1 Apprendimento non supervisionato

“Come tutti gli altri tipi di apprendimento automatico questi metodi mirano ad estrarre della conoscenza in maniera automatica a partire da basi di dati. In questo particolare caso tale operazione avviene senza una specifica conoscenza a priori dei contenuti da analizzare. Al sistema vengono infatti forniti dei dati in input (esperienza del sistema) che egli classificherà e organizzerà in base a caratteristiche comuni, con lo scopo di prevedere dei comportamenti o delle situazioni che potrebbero presentarsi nel momento in cui al sistema verranno dati altri dati in input. I dati in input però, a differenza di quanto accade nel caso dell'apprendimento supervisionato, non sono etichettati, ovvero non hanno nessuna corrispondenza con dei dati in output” (Gabriele, 2019). Il compito principale dell'apprendimento non supervisionato è il Clustering, ossia una tecnica di intelligenza artificiale, che ha l'obiettivo di selezionare e raggruppare elementi che hanno proprietà simili in un determinato insieme di dati, senza che il

sistema sia stato addestrato (Behmann et al., 2015). Gli elementi con caratteristiche analoghe sono definite “clusters” (Gabriele, 2019). Nel rilevamento delle infestanti, questo metodo può essere applicato:

- in fase di pre-elaborazione: utilizzato da Tang et al. (2018, 2017);
- in fase di post-elaborazione: adoperato da Cheng e Matson (2015);
- per filtrare le immagini: (Kumar e Prema, 2016);
- in fase di segmentazione: (Kumar e Prema, 2016).

1.12.1.2 Apprendimento supervisionato

A differenza dell'apprendimento precedentemente trattato, nell'apprendimento supervisionato vengono forniti in input dei dati che sono stati annotati, i quali rappresentano specifici output che vogliamo ottenere (Singh et al., 2016).

Questo metodo prevede due fasi:

1. addestramento di un modello: vengono forniti come input dati originali e dati etichettati;
2. il modello, una volta che è stato addestrato, viene applicato su determinati dati sconosciuti con il fine di ottenere output etichettati dalla macchina stessa in maniera autonoma (Behmann et al., 2015).

Le “etichette” rappresentano le malerbe, la coltura di interesse o specifiche specie vegetali.

Generalmente, si applicano due algoritmi di apprendimento supervisionato per il rilevamento delle malerbe (Behmann et al., 2015):

- SVM: *Support Vector Machine*
- ANN: *artificial neural networks*.

- SVM: *Support Vector Machine*

Le macchine a vettori di supporto sono specifici modelli che sono stati attuati per:

- discriminazione tra il mais e le malerbe: (Wu e Wen, 2009);
- identificazione di specie vegetali infestanti nei campi di mais: (Akbarzadeh et al., 2018; Guerrero et al., 2012; Lin, 2009);
- distinzione tra malerbe a foglia larga e foglia stretta: (Siddiqi e Seok-Won Lee, 2014).

- ANN: *artificial neural networks*

Le reti neurali artificiali sono modelli computazionali costituiti da neuroni artificiali che si ispirano alle reti neurali biologiche del cervello umano (van Gerven e Bohte, 2018). “Le reti neurali del cervello umano infatti sono la sede della capacità di comprensione dell’ambiente e dei suoi mutamenti e sono in grado di fornire risposte adattive appositamente calibrate sulle esigenze che si presentano” (Gabriele, 2019). “La caratteristica chiave di questi sistemi sta nel fatto di apprendere sfruttando meccanismi simili a quelli dell’intelligenza umana, conferendogli prestazioni impossibili da raggiungere per altri algoritmi” (Gabriele, 2019). Tuttavia, queste reti necessitano di risorse hardware notevoli per operare correttamente (Gabriele, 2019). Le reti neurali artificiali sono state utilizzate per diverse ricerche, tra cui:

- segmentazione di specie vegetali in condizioni variabili di illuminazione: (Hong Y. Jeon et al., 2011);
- classificazione tra i generi *Amaranthus L.*, *Chenopodium*, *Conringia*, *Rapistrum*: (Bakhshipour et al., 2017);
- discriminazione tra diverse specie vegetali: (Chaki et al., 2015);
- identificazione di tre tipi di infestanti (*Secale cereale L.*, *Polygonum aviculare L.*, *Xanthium strumarium L.*) (Sabzi et al., 2018).

- Considerazioni sulle prestazioni di SVM e ANN

Bakhshipour e Jafari (2018) hanno valutato il rilevamento di *Amaranthus L.*, *Chenopodium*, *Conringia*, *Rapistrum* in campi di barbabietola da zucchero ottenendo risultati con:

- livello accuratezza del metodo SVM: 95,00%;
- livello accuratezza del metodo ANN: 92,92%.

Anche la ricerca di Pereira et al. (2012), nel rilevamento delle specie vegetali infestanti acquatiche, ha prodotto risultati con un livello di precisione di SVM migliori rispetto ad ANN.

1.12.2 Classificazione basata sul deep learning

Negli ultimi anni, alcuni algoritmi di deep learning sono stati utilizzati per il rilevamento delle specie vegetali. In particolare:

- CNN (Convolutional Neural Network): rete neurale convoluzionale;
- U-Net.

- CNN (Convolutional Neural Network)

Potena et al. (2017) si è servito di due differenti CNN per processare immagini RGB e nel vicino infrarosso (NIR) per identificare accuratamente le specie vegetali:

- CNN leggera: è stata impiegata per una segmentazione rapida e robusta delle colture e delle piante infestanti;
- CNN profonda: è stata utilizzata per classificare i pixel estratti tra le classi della coltura di interesse e le malerbe.

La rete ha generato un livello medio di accuratezza nei risultati del 98,7%.

- U-Net:

“La CNN che si basa sull’architettura U-Net consiste in una serie di codifiche e contrazioni che servono per estrarre il contesto dell’immagine, seguite da una sequenza di decodifica ed espansione simmetrica. Questi ultimi processi servono per ricavare la classificazione di ogni singolo pixel. Ogni *step* che riguarda la contrazione riceve in ingresso un’immagine è caratterizzato da 4 blocchi concatenati, ognuno dei quali presenta due strati convoluzionali, uno strato di *batch normalization* ed una funzione di attivazione *ReLU*, ed in fine un ultimo blocco di *max-pooling*. Per ogni blocco, il numero di filtri che vengono applicati, sarà il doppio di quello precedente, ovvero si parte da 64 *feature maps* estratte dal primo blocco, fino ad arrivare a 512 feature del quarto blocco. Durante questa fase notiamo che le informazioni riguardanti le feature vengono incrementate, mentre quelle che riguardano le informazioni spaziali diminuiscono tramite l’operazione di campionamento. La seconda parte dell’architettura, ovvero quella che riguarda l’espansione, è formata anch’essa di 4 blocchi e ognuno di questi permette di concatenare l’immagine sovra-campionata con quella che corrisponde al percorso di contrazione e successivamente applicare le due unità convoluzionali, identiche a quelle della fase precedente. Alla fine, le feature che usciranno dall’ultimo livello saranno di dimensione uguale a quella dell’immagine in ingresso ma con un numero più elevato di canali. Per concludere, lo strato di classificazione softmax si occupa di assegnare ad ogni pixel dell’immagine l’etichetta in base alla categoria di appartenenza” (Ventura, 2020, Farhana et al., 2020, Zorzan, 2020).

2. Scopo della ricerca

La ricerca è stata realizzata con lo scopo di stimare concretamente la potenzialità dell'impiego dei droni per il rilevamento delle specie infestanti in una coltura di mais.

Lo studio si è focalizzato sui seguenti obiettivi:

- valutare l'applicabilità di paradigmi di deep learning mediante la creazione di una rete neurale profonda per la segmentazione e l'elaborazione di immagini catturate dal drone;
- valutare l'applicabilità della rete neurale ai fini del computo dell'indice Fraction Vegetation Cover (FVC);
- valutare se le tecniche utilizzate sono influenzate dall'altezza di volo (10, 15 e 20 metri) e dallo stadio di sviluppo delle piante infestanti tra il primo ed il secondo volo.

3. Materiali e metodi

Lo studio è stato effettuato presso il Centro di Ricerche Agro-Ambientale “E. Avanzi” dell’Università di Pisa, nell’appezzamento “Sodi 2”, tra il mese di giugno e il settembre dell’anno 2018.

I principali interventi riguardanti la conduzione agronomica del mais sono riportati nella tabella 3.1.

Tabella 3.1: *Principali interventi agrotecnici eseguiti sulla superficie utilizzata per la ricerca.*

Lavorazione principale	Ripuntatura: a 40 cm di profondità Erpicatura
Fertilizzazione	NPK (8:24:24): 4 q/ha CO(NH ₂) ₂ : 2 q/ha
Lavorazioni secondarie	Erpicatura
Semina: 04/06/2018	Densità semina: 8 semi/m ²
Mais	varietà PIONER P1547 classe FAO 600
Diserbo chimico	Post emergenza NIFURON: 1,5 l/ha ARIC 480 L.S.: 0,5 l/ha
Lavorazioni complementari	Sarchiatura

3.1 Organizzazione della superficie di lavoro

La sperimentazione è iniziata il 22 giugno 2018. Per lo svolgimento dell'attività, sono stati scelti due appezzamenti adiacenti:

- appezzamento 1: il campo dove è stato applicato il diserbo (DIS);
- appezzamento 2: il campo dove non vi è stato effettuato il diserbo (TEST).

Per ogni appezzamento sono state individuate quattro parcelle di area pari a 4 m^2 :

- DIS: 1, 2, 3, 4;
- TEST: 1, 2, 3, 4.

Inoltre, come è possibile notare nella figura 3.1, ogni parcella è stata suddivisa in quattro quadranti.

Figura 3.1: Esempio di parcella 4 m^2 .



3.2 Proprietà pedologiche degli appezzamenti

Presso il laboratorio del centro “E. Avanzi” è stato analizzato il terreno dove si è condotta la sperimentazione. Dai due appezzamenti sono stati prelevati sei campioni ad una profondità di circa 20 cm.

Tabella 3.2: *Proprietà fisiche e chimiche del terreno.*

Caratteristiche	DIS	TEST
Sabbia (%)	34	32
Limo (%)	36	38
Argilla (%)	29	29
Conducibilità (microS)	89,56	90,33
pH (-)	8,12	8,10
Azoto totale (metodo Kjeldhal) (g/kg)	1,38	1,40
Sostanza organica (metodo Walkley-Black) (%)	2,17	2,28
C.S.C. (mEq/100g)	19,24	16,82
Fosforo assimilabile (metodo Olsen) (ppm)	3,95	3,49

3.3 Drone “Agri-Efesto”

I voli sono stati effettuati utilizzando il drone “Agri-Efesto”, realizzato dall’azienda Sigma Ingegneria e dal gruppo Agricoltura di Precisione del CNR-IBIMET di Firenze.

Tabella 3.3: *Caratteristiche tecniche del drone “Agri-Efesto”*

Tipo di drone	Esacottero
Peso max al decollo	5 Kg
Carico utile	1 Kg
Tempo medio di volo per batteria	15 minuti

I sensori equipaggiati sul drone “Agri-Efesto” erano:

- **sensore visibile:** SONY QX100 da 20 Megapixel modificato;
- **sensore termico/multispettrale:**
 - camera FLIR TAU 2 con ottica da 13 mm con remotizzazione del segnale video e scatto continuo;
 - camera ADC SNAP con remotizzazione del segnale video e scatto continuo georiferito;



Figura 3.2: *Drone “Agri-Efesto” impiegato durante la ricerca.*

3.4 Voli effettuati

Durante la ricerca sono stati effettuati voli a diverse quote (10 m, 15 m, 20 m) in tre date diverse:

- **primo volo:** 25 giugno, piante alte 15 cm, tempo zero (prima osservazione);
- **secondo volo:** 07 luglio, piante alte 20 cm, circa 10 giorni post-diserbo;
- **terzo volo:** 13 luglio, piante alte 25 cm, circa 15 giorni post-diserbo.

3.5 Modalità di volo

I voli sono stati eseguiti in modalità GPS mode (semiautomatica), attraverso un percorso prestabilito, come è possibile notare nella figura 3.3, affinché l'overlap alle diverse altezze di volo rimanesse invariato, utilizzando il sistema di navigazione a bordo.



Figura 3.3: Waypoints e piani di volo impostati alle altezze di 10 m, 15 m e 20 m.

3.6 Selezione delle immagini per scopi di fotogrammetria

Le immagini digitali catturate dal drone sono state selezionate per ottenere un risultato di segmentazione migliore.

La tabella 3.4 mostra le immagini selezionate per ogni:

- parcella:
 - DIS 1, 2, 3, 4;
 - TEST 1, 2, 3, 4;
- volo: 1, 2, 3;
- altezza: 10 m, 15 m, 20 m.

Tabella 3.4: *Selezione delle immagini per ogni parcella, volo e altezza*

Parcelle	1_10	1_15	1_20	2_10	2_15	2_20	3_10	3_15	3_20
N_4	6893	7113	6703	6816	6724	6726	6894	7149	7560
N_3	6888	7117	6699	6822	6720	6722	6888	7144	7557
N_2	6884	7120	6697	6825	6717	6720	6885	7141	7555
N_1	6877	7125	6693	6831	6713	6716	6879	7136	7534
D_4	7158	7219	6819	7065	6862	6841	7108	7289	7717
D_3	7295	7267	6863	7269	6912	6846	7245	7338	7717
D_2	7175	7233	6831	7047	6876	6853	7125	7302	7687
D_1	7184	7240	6837	7038	6882	6858	7134	7309	7693

3.7 Metodologia pre-Deep Learning

Una volta ottenute le immagini, acquisite tramite SAPR, la metodologia pre-Deep Learning prevede le seguenti fasi:

- a. preparazione dataset;
- b. annotazione delle immagini;
- c. training base di modelli di analisi delle immagini e test.

3.7.1 Preparazione dataset

Le immagini digitali, acquisite dal drone, sono state catalogate e suddivise in sottogruppi.

3.7.2 Etichettatura delle immagini digitali

Attraverso il programma Labelbox, le immagini sono state annotate manualmente per separare le piante di mais, le specie vegetali infestanti e il terreno.

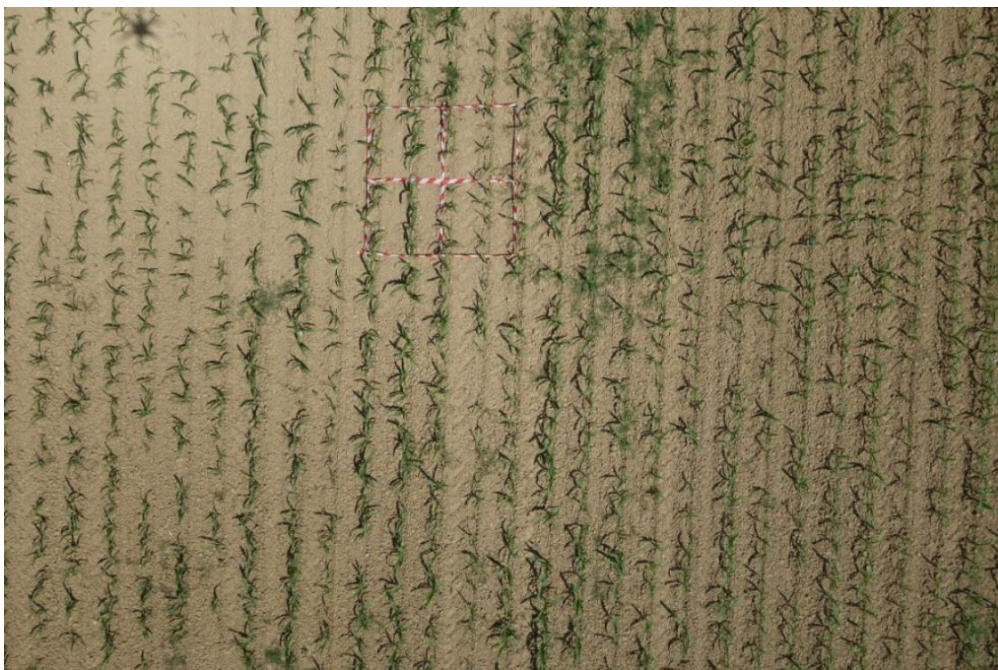


Figura 3.4: Annotazione manuale dell'immagine 7184 del primo volo. Quota: 10 metri. 25 giugno 2018.




Figura 3.5: Annotazione dell'immagine 7184 per la discriminazione delle piante del primo volo. Quota: 10 metri. Piante di mais: in celeste; piante infestanti: in giallo. 25 giugno 2018.




Figura 3.6: Annotazione manuale dell'immagine 7038 del secondo volo. Quota: 10 m. 7 luglio 2018.

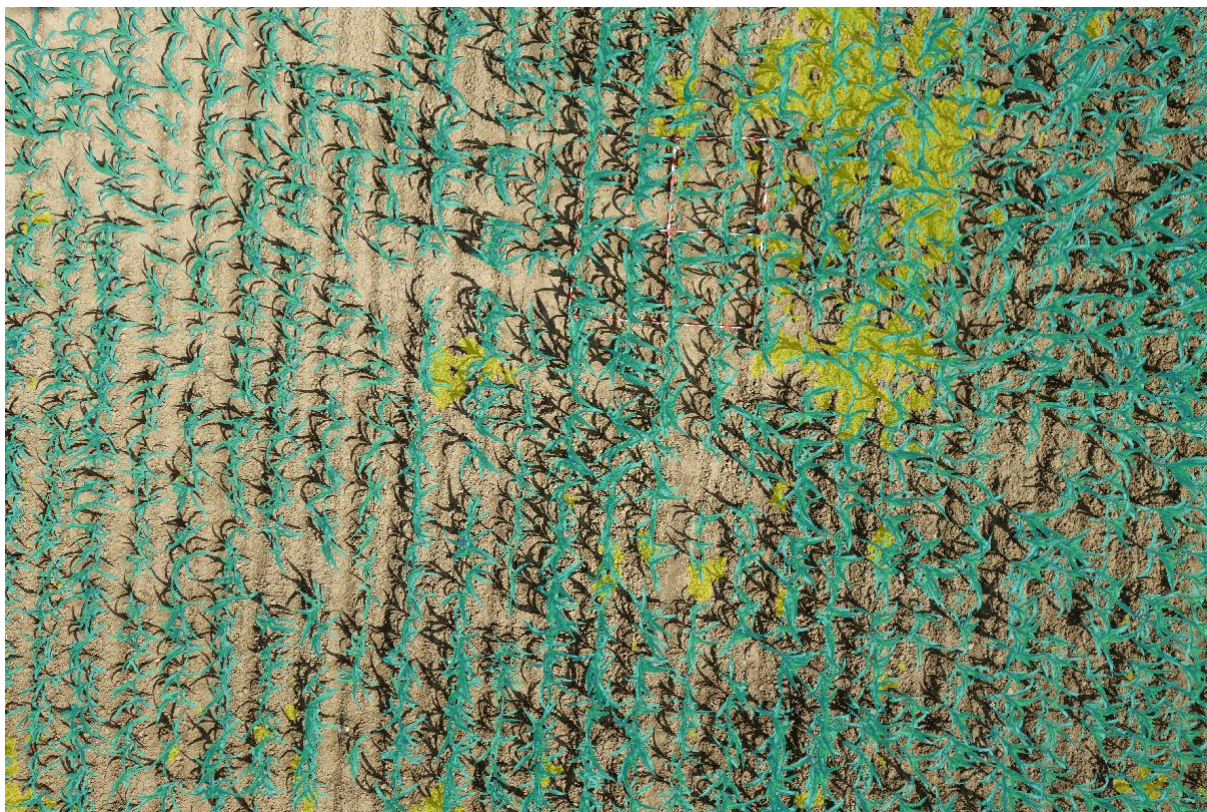


Figura 3.6: *Annotazione dell'immagine 7038 per la discriminazione delle piante del secondo volo. Quota: 10 m. Piante di mais: in celeste; piante infestanti: in giallo. 7 luglio 2018.*




Figura 3.7: *Particolare di annotazione manuale della parcella dell'immagine 7038.*

3.7.3 Training base di modelli di analisi delle immagini e test

Le immagini, una volta etichettate, sono state scaricate ed esportate in formato JSON dal sito di Labelbox da un membro dello staff del “Laboratorio Segnali e Immagini” del CNR-ISTI di Pisa. Successivamente ciascuna immagine originale, di dimensione 5472 x 3648 pixels, è stata ritagliata in patch da 512 x 512 pixels. Lo stesso pattern di patch da 512 x 512 pixels è stato fatto sulle immagini annotate manualmente. Dopodiché, sono state create delle maschere, come mostrato nella figura 3.8, delle piante infestanti e delle piante di mais. A questo punto abbiamo fornito degli esempi alla rete neurale U-Net per il suo addestramento, in particolare:

- patch estratti dalle immagini originali: come esempi di input;
- patch estratti dalle immagini annotate: come esempi di output, tra cui le patch delle maschere delle specie vegetali infestanti e le patch delle maschere delle piante di mais.

In sintesi, nella rete neurale sono stati forniti come input sia le immagini originali sia i risultati desiderati, ossia le immagini annotate. L’obiettivo della rete è l’identificazione di una regola o di parametri generali, che collegano i dati in input con quelli in output, in modo da riutilizzarli per altri compiti simili. Questo processo viene chiamato “addestramento”. A questo punto, una volta che la rete neurale è stata addestrata, sono stati effettuati due test:

- **Primo test:** la rete è stata testata su immagini note presenti nel sottoinsieme del dataset creato con Labelbox per valutare la precisione.

- **Secondo test:** la rete è stata testata su immagini non segmentate precedentemente per esaminare l’efficacia delle procedure messe a punto e per osservare nelle immagini il:

- Fraction Vegetation Cover (FVC) del mais;
- Fraction Vegetation Cover (FVC) delle specie vegetali infestanti;
- Fraction Vegetation Cover (FVC) della vegetazione totale.




Figura 3.8: *Generazione maschere da annotazione manuale della parcella diserbata D2 del primo volo.*
Quota: 10 m.

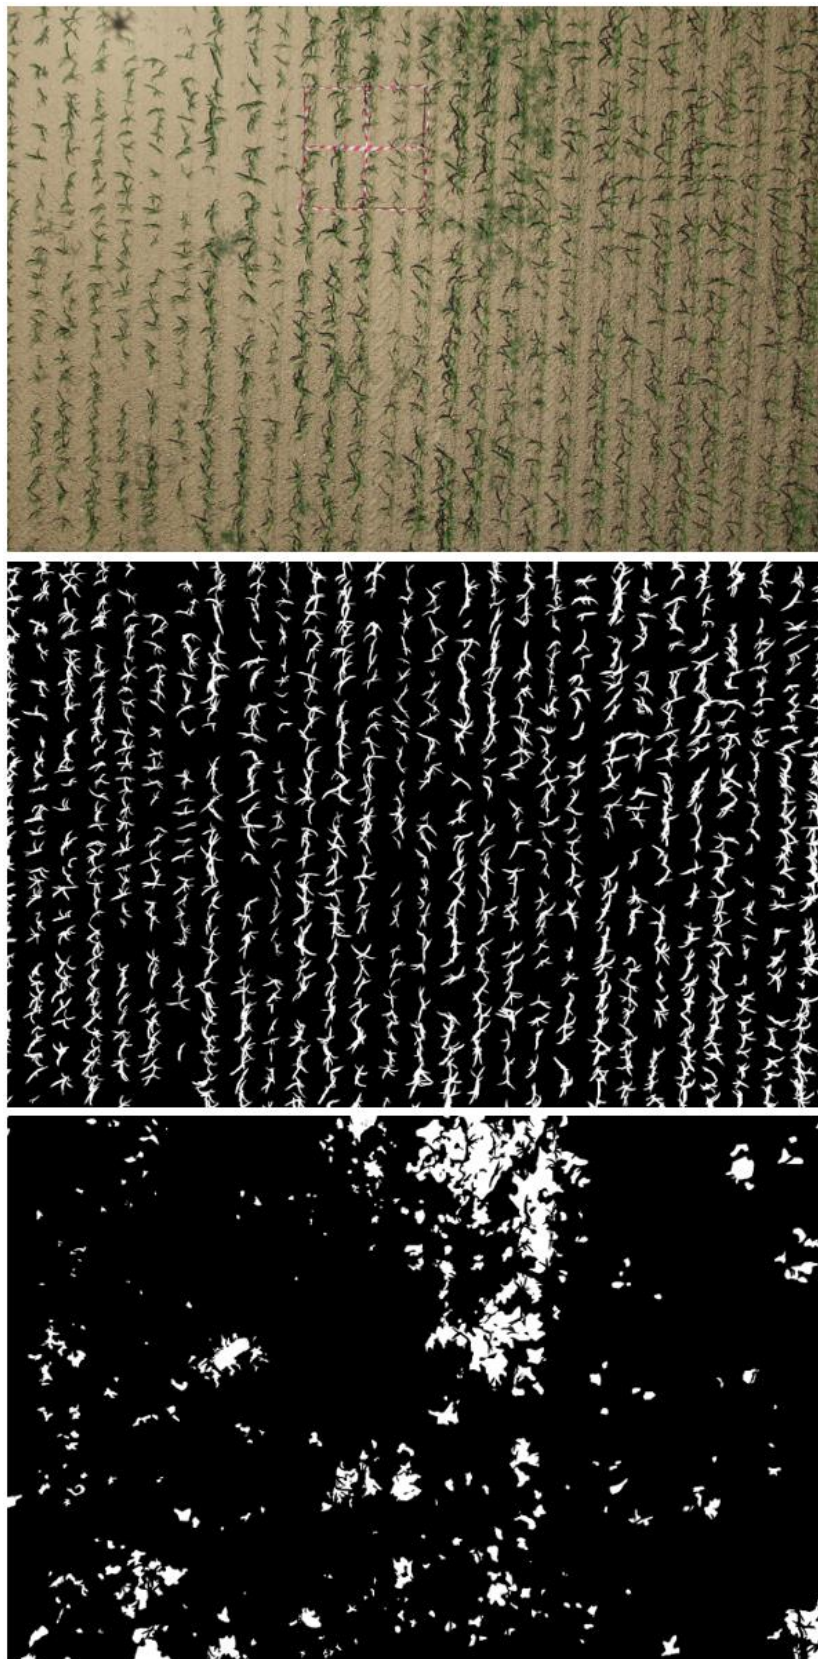


Figura 3.9: *Generazione maschere da annotazione manuale dell'immagine 7184.*




Figura 3.10: *Generazione maschere da annotazione manuale dell'immagine 7038.*

3.8 Fraction Vegetation Cover (FVC)

Il Fraction Vegetation Cover (FVC) o frazione di copertura vegetale esprime la quota di superficie occupata dalle specie vegetali. Attraverso questo indice è possibile valutare:

- lo sviluppo della coltura di interesse;
- l'entità delle malerbe.

Il calcolo dell'indice FVC è stato effettuato sulle immagini ricavate dal drone. In particolare sono stati ottenuti tre indici diversi di FVC:

- FVC Mais: frazione di copertura del mais;
- FVC Weed: frazione di copertura delle infestanti;
- FVC Totale: frazione di copertura della vegetazione totale;

FVC Mais: frazione di copertura del mais

Il calcolo dell'indice FVC del mais è stato effettuato, sia nelle immagini annotate manualmente che dalla rete neurale, calcolando il numero di pixel classificati come mais sul numero totale di pixel presenti.

FVC Weed: frazione di copertura delle infestanti

Il calcolo dell'indice FVC delle malerbe è stato effettuato, sia nelle immagini annotate manualmente che dalla rete neurale, calcolando il numero di pixel classificati come specie vegetale infestante sul numero totale di pixel presenti.

FVC Totale: frazione di copertura della vegetazione totale

Il calcolo dell'indice FVC della vegetazione totale è stato effettuato, sia nelle immagini annotate manualmente che dalla rete neurale, calcolando la somma tra:

- FVC del mais;
- FVC delle malerbe.

3.9 Programmi utilizzati: Labelbox e GIMP:

- Labelbox;
- Gimp.

3.9.1 Labelbox:

Labelbox è una piattaforma per creare e gestire dati di formazione. In particolare, Labelbox è uno strumento di:

- etichettatura delle immagini e per la classificazione delle stesse;
- rilevamento di oggetti;
- segmentazione.

Per annotare le immagini possiamo utilizzare diversi strumenti personalizzabili a seconda del tipo di lavoro che stiamo effettuando, tra cui le principali: rettangoli di selezione, punti, linee, poligoni e toolkit di segmentazione delle istanze: penna e super pixel. Nel mio caso specifico è stato utilizzato per il rilevamento delle specie infestanti.




Figura 3.11: *Interfaccia di labelbox.*

Keyboard shortcuts, Drawing tools ed altri strumenti personalizzabili

Questi strumenti personalizzabili ci permettono di:

- annotare le immagini;
- migliorare alcuni parametri dell'immagine che stiamo annotando: ad esempio possiamo aumentare il contrasto.

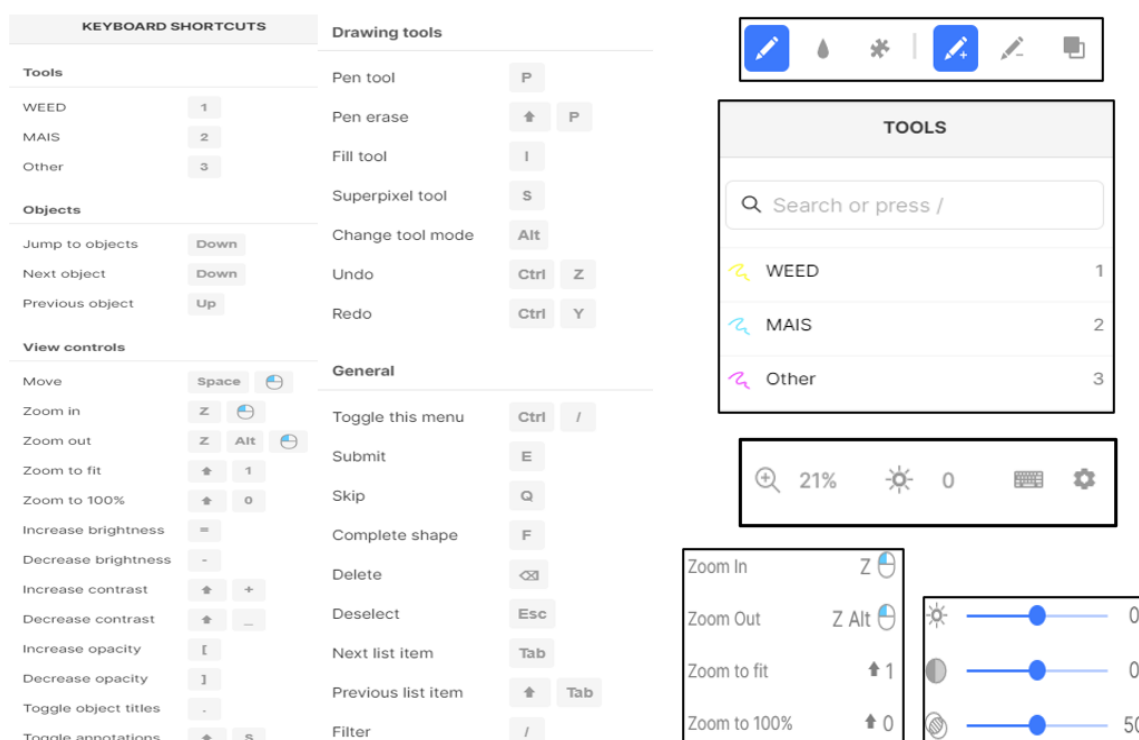


Figura 3.12: Keyboard shortcuts, Drawing tools ed altri strumenti personalizzabili.

3.9.2 GIMP: GNU Image Manipulation Program

È un software libero distribuito gratuitamente per diverse attività per l'elaborazione digitale delle immagini come ritocco fotografico, fotomontaggi e creazione di immagini, conversioni tra molteplici formati di file ed animazioni.



3.10 Analisi statistica

Per verificare la rispondenza della rete neurale abbiamo lavorato su immagini di grandi dimensioni in modo da avere un'ampia base informativa su cui basare i nostri giudizi. L'analisi statistica è stata svolta utilizzando il software Graph Pad prism (Graph Software, San Diego, CA, USA).

Le immagini che sono state analizzate sono la numero 7184 e la 7038, le quali verranno descritte meglio nel prossimo capitolo. Ciascun immagine è stata suddivisa in 88 patch. Come descritto nelle tabelle 3.5 e 3.6, in fondo al capitolo, in ogni patch sono presenti i valori dell'indice FVC (%) del mais, delle infestanti e della vegetazione totale.

Per valutare la normalità delle distribuzioni relative agli indici di copertura sono stati usati i seguenti test:

- D'Agostino & Pearson normality test;
- Shapiro-Wilk normality test;
- KS normality test.

Successivamente sono stati adoperati i seguenti test:

- test t di Student: test parametrico;
- Wilcoxon test: test non parametrico.

3.11 Immagini analizzate

- **Immagine 7184: DIS-A**

Questa immagine è stata catturata durante il primo volo della parcella non ancora diserbata (D2) il giorno 25 giugno 2018, dimensione 5472 x 3648 pixels. Per semplificare la chiameremo: DIS-A.

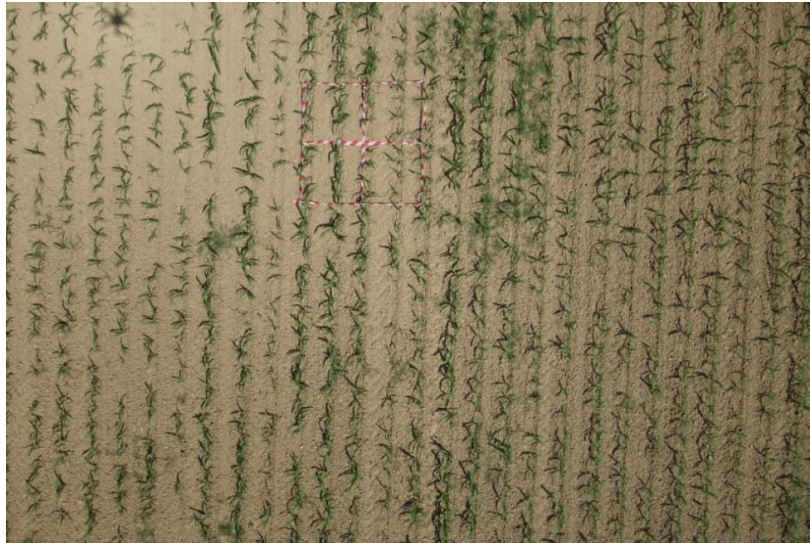


Figura 3.12: immagine DIS-A.

- **Immagine 7038: DIS-B**

Immagine catturata durante il secondo volo della parcella diserbata (D2) il giorno 7 luglio 2018, dimensione 5472 x 3648 pixels. Per semplificare la chiameremo: DIS-B.



Figura 3.13: immagine DIS-B

Valori FVC (%) mais, infestanti e della vegetazione totale per ogni patch dell'immagine DIS-B

Patch segmentate della rete neurale

Filename	MAIS(%)	WEED(%)	TOTAL(%)
0_0.png	17.7	0.6	18.3
0_1.png	15.5	0	15.5
0_2.png	12.5	2.2	14.6
0_3.png	10.9	3.6	14.4
0_4.png	16	2.3	18.2
0_5.png	12.1	0.5	12.6
0_6.png	6.2	0	6.2
0_7.png	0.1	3.1	3.2
10_0.png	9	0	9
10_1.png	11.3	0	11.4
10_2.png	17.2	0.8	18.1
10_3.png	29.6	1.1	30.6
10_4.png	19	0.4	19.4
10_5.png	12.6	0	12.6
10_6.png	8.9	6.3	15.2
10_7.png	16.2	9	25.1
1_0.png	10.4	1.9	12.2
1_1.png	12	0	12
1_2.png	16.6	0	16.7
1_3.png	13.8	0.2	14
1_4.png	12.4	0	12.4
1_5.png	14.9	3.7	18.5
1_6.png	22.4	4.2	26.6
1_7.png	6.8	22.6	29.4
2_0.png	8.7	0	8.7
2_1.png	16.5	0	16.5
2_2.png	4	1.4	5.4
2_3.png	11.6	9.5	21.1
2_4.png	9.2	0	9.2
2_5.png	7.8	1.4	9.3
2_6.png	5.4	7.2	12.6
2_7.png	5.9	6.4	12.3
3_0.png	11.2	0	11.2
3_1.png	12.5	0	12.5
3_2.png	16.3	1.3	17.6
3_3.png	12.9	0.1	13
3_4.png	10.4	0	10.4
3_5.png	12.9	0	12.9
3_6.png	13.2	1.6	14.8
3_7.png	19.2	0	19.2
4_0.png	20.8	16.3	37.1
4_1.png	15.4	0.2	15.6
4_2.png	11	0	11
4_3.png	12	0	12
4_4.png	10.7	5.5	16.2
4_5.png	7.4	0	7.4
4_6.png	6.8	0.8	7.6
4_7.png	4	0	4
5_0.png	8.4	31.4	39.9
5_1.png	11.2	7.8	19
5_2.png	12.7	8.7	21.4
5_3.png	8.6	1.6	10.3
5_4.png	6.6	8.4	15
5_5.png	7.8	0.3	8.1
5_6.png	15.7	1.9	17.6
5_7.png	4.1	0	4.1
6_0.png	9.3	56.5	65.8
6_1.png	8.4	27.5	35.9
6_2.png	9.1	38	47.1
6_3.png	3.4	18.1	21.5
6_4.png	8.2	5	13.2
6_5.png	9.7	3.5	13.2
6_6.png	5.4	4	9.4
6_7.png	8.2	0	8.2
7_0.png	13.2	11.7	24.9
7_1.png	16.9	6.4	23.4
7_2.png	14	0.4	14.4
7_3.png	5.9	1.3	7.2
7_4.png	6.4	0.9	7.3
7_5.png	9.7	0	9.7
7_6.png	8.8	0	8.8
7_7.png	0.5	0	0.5
8_0.png	13.9	0	13.9
8_1.png	10.3	1.1	11.4
8_2.png	8.6	0	8.6
8_3.png	8.7	0.2	8.9
8_4.png	9.5	0	9.5
8_5.png	15.3	0	15.3
8_6.png	16.9	1.6	18.5
8_7.png	7.1	0	7.1
9_0.png	9.9	7.1	17
9_1.png	19.4	0	19.4
9_2.png	12.5	0	12.5
9_3.png	6.3	0.8	7.1
9_4.png	7.8	0	7.8
9_5.png	8.9	0	8.9
9_6.png	11.8	0	11.8
9_7.png	10	0	10

Patch segmentate manualmente

Filename	MAIS(%)	WEED(%)	TOTAL(%)
0_0.png	17.3	0.6	17.9
0_1.png	14	1.3	15.3
0_2.png	12.9	3.2	16.1
0_3.png	10.7	9	19.7
0_4.png	12.6	5.4	18
0_5.png	12.4	1.9	14.3
0_6.png	10	6.9	16.9
0_7.png	3.1	14.9	18
10_0.png	13.5	6.3	19.8
10_1.png	16.9	9.7	26.6
10_2.png	21.3	4.7	26.1
10_3.png	23.7	0.2	23.9
10_4.png	19.7	1	20.7
10_5.png	17.8	0	17.8
10_6.png	19.9	24.6	44.6
10_7.png	16.5	37.5	54
1_0.png	10.2	5	15.2
1_1.png	11.9	0.6	12.5
1_2.png	13.2	0.4	13.6
1_3.png	12.6	2.5	15.1
1_4.png	11.5	1.3	12.8
1_5.png	13.4	8.3	21.7
1_6.png	17.1	16.6	33.7
1_7.png	9.9	33.1	43
2_0.png	9.4	0	9.5
2_1.png	14.3	0	14.3
2_2.png	5.3	2	7.3
2_3.png	10.1	14.1	24.2
2_4.png	9.7	0.1	9.8
2_5.png	9.1	6.2	15.3
2_6.png	8.1	9.5	17.5
2_7.png	8.6	25.7	34.3
3_0.png	10.5	0.1	10.6
3_1.png	10.4	1.7	12.1
3_2.png	12.8	1.7	14.5
3_3.png	13.1	3.5	16.6
3_4.png	12.3	1.9	14.2
3_5.png	12.8	0.8	13.6
3_6.png	16	3.9	19.9
3_7.png	20.9	6.4	27.3
4_0.png	16	16.8	32.8
4_1.png	10.9	1.5	12.3
4_2.png	11.9	0	11.9
4_3.png	11.8	0	11.8
4_4.png	11	13.3	24.3
4_5.png	11.4	1.7	13.1
4_6.png	11.9	3.3	15.2
4_7.png	17.8	2.7	20.5
5_0.png	7.8	35.8	43.6
5_1.png	11.5	13.7	25.1
5_2.png	11.7	13	24.8
5_3.png	11.9	6	17.9
5_4.png	11.9	13.9	25.7
5_5.png	11.2	5.9	17.1
5_6.png	18.8	5.4	24.2
5_7.png	10.3	0	10.3
6_0.png	12.5	61.3	73.8
6_1.png	13.1	36	49.1
6_2.png	12.9	42.4	55.3
6_3.png	7.5	24.8	32.3
6_4.png	11.8	12.1	23.9
6_5.png	15.1	10	25.1
6_6.png	13	13.1	26.1
6_7.png	13.9	0	13.9
7_0.png	14	18.6	32.6
7_1.png	16.6	11.1	27.7
7_2.png	13.9	2.9	16.8
7_3.png	9.7	3	12.8
7_4.png	12.7	2.4	15.1
7_5.png	13.1	0.5	13.6
7_6.png	13.3	2.8	16.1
7_7.png	8.5	0	8.5
8_0.png	14.1	0	14.1
8_1.png	12.1	0.6	12.7
8_2.png	12.4	1.3	13.6
8_3.png	13.2	1.9	15.1
8_4.png	12.6	0.9	13.5
8_5.png	16.8	2.3	19.1
8_6.png	17.9	2.8	20.8
8_7.png	21.3	5.7	27
9_0.png	14.2	10	24.2
9_1.png	20	0	20
9_2.png	17.1	0	17.1
9_3.png	11.4	2.5	13.9
9_4.png	10.7	1.8	12.5
9_5.png	12.6	3.4	16
9_6.png	16.7	0.2	16.9
9_7.png	20.8	0	20.8

Tabella 3.6: Valori FVC (%) ricavati dalle patch segmentate della rete neurale e manualmente.

Valori FVC (%) mais, infestanti e della vegetazione totale per ogni patch dell'immagine DIS-A

Patch segmentate della rete neurale

Filename	MAIS(%)	WEED(%)	TOTAL(%)
0_0.png	51.8	0	51.9
0_1.png	39.5	0.1	39.6
0_2.png	55.9	0	55.9
0_3.png	52.6	0	52.6
0_4.png	45.2	0	45.2
0_5.png	34.2	0	34.2
0_6.png	27.1	4.7	31.9
0_7.png	18.5	0	18.5
10_0.png	58.9	0.2	59
10_1.png	59.4	0.2	59.5
10_2.png	74.2	0	74.2
10_3.png	58.4	0	58.4
10_4.png	56.2	0.8	57
10_5.png	77.2	0.1	77.3
10_6.png	73.9	0	73.9
10_7.png	73.5	0	73.5
1_0.png	42.3	0	42.3
1_1.png	32.2	0	32.2
1_2.png	27.9	0	27.9
1_3.png	20	0	20
1_4.png	28.5	0	28.5
1_5.png	37.4	0	37.4
1_6.png	32	0	32
1_7.png	5.6	0	5.6
2_0.png	41.9	0.1	42.1
2_1.png	38.3	0	38.3
2_2.png	39.1	0	39.1
2_3.png	39.3	0	39.3
2_4.png	30.3	0	30.3
2_5.png	21.5	0	21.5
2_6.png	27.6	0.1	27.7
2_7.png	0.6	0.1	0.8
3_0.png	34.6	0	34.6
3_1.png	43.7	0	43.7
3_2.png	17.5	0	17.5
3_3.png	23.2	3.7	26.9
3_4.png	21.9	0	21.9
3_5.png	24.6	0	24.6
3_6.png	27.6	0.8	28.4
3_7.png	18.6	13	31.6
4_0.png	39.8	0	39.8
4_1.png	26.4	0	26.4
4_2.png	21.8	0	21.8
4_3.png	27.1	1.5	28.6
4_4.png	34.4	0	34.4
4_5.png	39.3	0	39.3
4_6.png	39	0	39
4_7.png	21.7	0	21.7
5_0.png	46.2	0.7	46.9
5_1.png	43.3	1.8	45.1
5_2.png	48.9	0	48.9
5_3.png	48.2	0.2	48.4
5_4.png	28.9	0.1	29
5_5.png	30.5	0.1	30.6
5_6.png	42.2	0	42.2
5_7.png	33.9	0	33.9
6_0.png	42.7	8.5	51.3
6_1.png	35.7	0	35.7
6_2.png	40.6	0.2	40.7
6_3.png	27.8	3.2	31
6_4.png	24.2	0.7	24.8
6_5.png	28.9	0.2	29
6_6.png	41.6	0	41.6
6_7.png	34.3	0	34.3
7_0.png	43.4	25.8	69.2
7_1.png	53.3	8.8	62.1
7_2.png	53.4	8.3	61.7
7_3.png	39.3	20.5	59.8
7_4.png	53.5	0.7	54.2
7_5.png	36	0	36.1
7_6.png	54.1	0	54.1
7_7.png	36.8	0	36.8
8_0.png	51.6	15.6	67.2
8_1.png	43.1	27.5	70.5
8_2.png	50.2	3.7	53.9
8_3.png	41.2	3	44.2
8_4.png	34.4	0	34.4
8_5.png	42.1	0.3	42.4
8_6.png	56.9	0.6	57.5
8_7.png	33	0	33
9_0.png	68.4	0.1	68.5
9_1.png	54.2	0.3	54.5
9_2.png	67.7	0	67.7
9_3.png	52.6	0	52.6
9_4.png	48.4	0	48.4
9_5.png	59.2	0	59.2
9_6.png	59.5	0	59.5
9_7.png	61	0	61

Patch segmentate manualmente

Filename	MAIS(%)	WEED(%)	TOTAL(%)
0_0.png	39.8	0	39.8
0_1.png	26.4	2.7	29.2
0_2.png	37	0.3	37.2
0_3.png	37.3	0.4	37.7
0_4.png	33.1	0.2	33.4
0_5.png	30.5	0.2	30.7
0_6.png	29.6	6.3	35.9
0_7.png	33.2	22.8	55.9
10_0.png	51.9	0	51.9
10_1.png	48.8	0	48.8
10_2.png	56.5	0	56.5
10_3.png	44.3	0	44.3
10_4.png	45.3	0	45.3
10_5.png	51.4	0.1	51.5
10_6.png	48.9	5.1	54
10_7.png	57.1	0	57.1
1_0.png	30.9	0	30.9
1_1.png	25	0	25
1_2.png	19	0.1	19
1_3.png	17.6	0	17.6
1_4.png	23	0.2	23.2
1_5.png	31	0	31
1_6.png	31.8	1.1	32.8
1_7.png	21.7	0	21.7
2_0.png	27.4	0	27.4
2_1.png	28.3	0	28.3
2_2.png	26.9	0	26.9
2_3.png	29.9	0	29.9
2_4.png	25	0	25
2_5.png	21.2	0.1	21.4
2_6.png	27.8	4.1	31.9
2_7.png	7.1	9.3	16.4
3_0.png	24.6	0	24.6
3_1.png	34.3	0	34.3
3_2.png	15.7	0	15.7
3_3.png	20.6	9.2	29.8
3_4.png	19.7	0	19.7
3_5.png	23.8	0	23.8
3_6.png	27.2	1.7	28.9
3_7.png	23.5	24.1	47.6
4_0.png	26.6	0	26.6
4_1.png	23.6	0	23.6
4_2.png	22	1.1	23.1
4_3.png	26.6	8.7	35.3
4_4.png	29.1	0.3	29.5
4_5.png	35.3	0	35.3
4_6.png	32	1.9	33.9
4_7.png	29.8	3.6	33.4
5_0.png	34	3.5	37.5
5_1.png	32.9	3.1	36
5_2.png	39	0	39
5_3.png	40.3	0	40.3
5_4.png	27.8	4.6	32.4
5_5.png	28.4	2.2	30.6
5_6.png	35.9	0	35.9
5_7.png	43.5	0	43.5
6_0.png	29.2	18.8	48
6_1.png	26.4	4.9	31.3
6_2.png	29.5	8.5	38
6_3.png	23.7	5.8	29.5
6_4.png	22.2	5.7	27.9
6_5.png	28.3	6.3	34.6
6_6.png	35.4	0.3	35.7
6_7.png	54.8	0.2	55
7_0.png	27	59	86.1
7_1.png	36.7	28.4	65.2
7_2.png	36.8	23.1	59.9
7_3.png	31.7	37.6	69.3
7_4.png	41.7	3.7	45.4
7_5.png	32	1.1	33.1
7_6.png	42	1.6	43.6
7_7.png	44.2	6.5	50.7
8_0.png	42.9	20.4	63.3
8_1.png	31.5	34	65.4
8_2.png	37.4	10.3	47.7
8_3.png	32.9	7.7	40.5
8_4.png	27	0	27
8_5.png	34.4	0	34.4
8_6.png	41.1	0	41.1
8_7.png	45.1	0	45.1
9_0.png	50	2.7	52.7
9_1.png	40.5	0.4	40.9
9_2.png	46	0	46
9_3.png	39.5	0	39.5
9_4.png	38.5	0	38.5
9_5.png	39.3	0.9	40.2
9_6.png	40.2	1.5	41.7
9_7.png	54	0	54

Tabella 3.5: Valori FVC (%) ricavati dalle patch segmentate della rete neurale e manualmente.

4. Risultati

Per ogni parcella, come illustrato nella tabella 4.1, sono stati ottenuti i valori FVC (%) del mais, delle infestanti e del totale della vegetazione relativi alle immagini catturate ad altezze (10 m, 15 m e 20 m) del primo volo.

Tabella 4.1: *Calcolo del Fraction Vegetation Cover (FVC) del primo volo.*

Parcelle	Altezza volo (m)	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 1	10	/	/	/
D 2	10	1.5	6.2	7.7
D 3	10	1.2	0	1.2
D 4	10	1.6	13.6	15.2
N 1	10	2.3	39.4	41.7
N 2	10	1.6	15.7	17.2
N 3	10	0.8	2.3	3.1
N 4	10	1.6	9.2	10.8

Parcelle	Altezza volo (m)	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 1	15	9.8	1.4	11.2
D 2	15	/	/	/
D 3	15	4.8	0	4.8
D 4	15	1.4	16.1	17.5
N 1	15	1.8	41.5	43.3
N 2	15	1.5	15.7	17.2
N 3	15	1.1	5	6.1
N 4	15	1.4	9.5	10.9

Parcelle	Altezza volo (m)	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 1	20	8.4	0.8	9.2
D 2	20	2.8	9.1	11.9
D 3	20	6.2	0.2	6.4
D 4	20	3.5	17.8	21.3
N 1	20	0	58.9	58.9
N 2	20	0.2	22.9	23
N 3	20	2.5	11.3	13.8
N 4	20	1.9	12.1	14

Inoltre sono stati ottenuti i valori FVC (%) del mais, delle infestanti e del totale della vegetazione relativi alle immagini catturate ad altezza 10 m del secondo volo.

Tabella 4.2: *Calcolo del Fraction Vegetation Cover (FVC) del secondo volo.*

Parcelle	Altezza volo	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 1	10	34.3	0.1	34.4
D 2	10	21.4	0.5	21.9
D 3	10	32	0.3	32.3
D 4	10	23.8	7.6	31.4
N 1	10	11	42.5	53.5
N 2	10	10.7	19.7	30.4
N 3	10	18	12.2	30.1
N 4	10	25	12.7	37.7

4.1 Differenza risultati di volo tra 10 m, 15 m e 20 m

4.1.1 FVC (%) mais del primo volo

Descrizione dei risultati:

Come è possibile osservare nella tabella 4.3 e nella figura 4.1, la rete neurale, nel volo a 10 m, ha mediamente rilevato meno pixels, classificati come piante di mais, rispetto ai voli di 15 m e 20 m, in particolare:

- passando da 10 a 15 metri: l'incremento è stato pari a 0.48% in termini assoluti e del 32% in termini relativi $[(FVC_{15m} - FVC_{10m}) / FVC_{10m}]$;
- passando da 15 a 20 metri: l'incremento è stato pari a 0.38% in termini assoluti e del 19% in termini relativi $[(FVC_{20m} - FVC_{15m}) / FVC_{15m}]$;
- complessivamente passando da 10 a 20 metri: l'incremento è stato pari a 0.86%% in termini assoluti e del 57% in termini relativi $[(FVC_{20m} - FVC_{10m}) / FVC_{10m}]$.

In sintesi possiamo osservare che aumentando l'altezza di volo la rete neurale è in grado di rilevare mediamente più pixels, classificati come piante di mais, in modo proporzionale.

Tabella 4.3: valori FVC (%) mais del primo volo.

Parcelle	FVC (%) 10 m	FVC (%) 15 m	FVC (%) 20 m
D3	1.2	4.8	6.2
D4	1.6	1.4	3.5
N1	2.3	1.8	0
N2	1.6	1.5	0.2
N3	0.8	1.1	2.5
N4	1.6	1.4	1.9
Media	1.52	2.00	2.38
Deviazione St.	0.50	1.39	2.30




Figura 4.1: media dei valori FVC (%) del mais del primo volo a diverse altezze.

4.1.2 FVC (%) Weed del primo volo

Descrizione dei risultati:

Come è possibile osservare nella tabella 4.4 e nella figura 4.2, la rete neurale ha prodotto risultati simili nei voli a 10 m e 15 m. Invece, rispetto a quest'ultimi, il volo a 20 m ha rilevato mediamente più pixels, in particolare:

- passando da 10 a 15 metri: l'incremento è stato pari a 1,26% in termini assoluti e del 9% in termini relativi $[(FVC_{15m} - FVC_{10m}) / FVC_{10m}]$;
- passando da 15 a 20 metri: l'incremento è stato pari a 5.9% in termini assoluti e del 40% in termini relativi $[(FVC_{20m} - FVC_{15m}) / FVC_{15m}]$;
- complessivamente passando da 10 a 20 metri: l'incremento è stato pari a 7.16% in termini assoluti e del 54% in termini relativi $[(FVC_{20m} - FVC_{10m}) / FVC_{10m}]$.

Esaminando il grafico si può osservare che tra il volo di 20 m e gli altri due voli (10-15 m) vi è una significativa differenza nel rilevamento delle specie infestanti.

Tabella 4.4: valori FVC (%) delle infestanti del primo volo.

Parcelle	FVC (%) 10 m	FVC (%) 15 m	FVC (%) 20 m
D3	0	0	0.2
D4	13.6	16.1	17.8
N1	39.4	41.5	58.9
N2	15.7	15.7	22.9
N3	2.3	5	11.3
N4	9.2	9.5	12.1
Media	13.37	14.63	20.53
Deviazione St.	14.15	14.55	20.27




Figura 4.2: media dei valori FVC (%) delle infestanti del primo volo a diverse altezze.

4.1.3 FVC (%) vegetazione totale del primo volo

Descrizione dei risultati:

Come è possibile osservare nella tabella 4.5 e nella figura 4.3, la rete neurale ha mediamente rilevato più pixels, classificati come vegetazione totale, nel volo a 20 m, rispetto alle altre quote di volo, in particolare:

- passando da 10 a 15 metri: l'incremento è stato pari a 1.76% in termini assoluti e del 12% in termini relativi $[(FVC_{15m} - FVC_{10m}) / FVC_{10m}]$;
- passando da 15 a 20 metri: l'incremento è stato pari a 3.95% in termini assoluti e del 38% in termini relativi $[(FVC_{20m} - FVC_{15m}) / FVC_{15m}]$;
- complessivamente passando da 10 a 20 metri: l'incremento è stato pari a 6.27% in termini assoluti e del 54% in termini relativi $[(FVC_{20m} - FVC_{10m}) / FVC_{10m}]$.

Tabella 4.5: valori FVC (%) della vegetazione totale del primo volo.

Parcelle	FVC (%) 10 m	FVC (%) 15 m	FVC (%) 20 m
D3	1.2	4.8	6.4
D4	15.2	17.5	21.3
N1	41.7	43.3	58.9
N2	17.2	17.2	23
N3	3.1	6.1	13.8
N4	10.8	10.9	14
Media	14.87	16.63	22.90
Deviazione St.	14.61	14.11	18.62




Figura 4.3: media dei valori FVC (%) della vegetazione totale del primo volo a diverse altezze.

4.1.4 Confronto tra il riconoscimento delle piante di mais e il riconoscimento delle infestanti

Come è possibile notare nella figura 4.1 e 4.2, all'aumentare della quota di volo possiamo osservare un significativo incremento del riconoscimento sia delle piante di mais che delle piante infestanti. In particolare:

- nel riconoscimento delle piante di mais e delle infestanti si può osservare un netto incremento nel volo a 20 m, rispetto ai voli a quota 10 m e 15 m.
- nel rilevamento della vegetazione totale possiamo osservare un aumento quasi proporzionale tra i voli a 10 m, 15 m e 20 m.

4.2 Differenza tra le parcelle diserbate e non diserbate dei voli a 10 m del secondo volo

Nel secondo volo, la ricerca si è concentrata in particolare sull'analisi del volo effettuato all'altezza di 10 metri.

Descrizione risultati

Nella tabella 4.6 e 4.7 e nella figura 4.4 e 4.5, è possibile osservare una significativa differenza tra i pixels, classificati come piante infestanti, nelle parcelle diserbate e non diserbate. In particolare l'indice FVC (%) delle infestanti si attesta:

- nelle parcelle diserbate al 2,13%;
- nelle parcelle non diserbate al 21.78%;

Complessivamente possiamo osservare una riduzione dell'indice FVC(%) delle infestanti di 19,65% tra le parcelle non diserbate e le parcelle non diserbate.

Inoltre, un altro dato che possiamo osservare, nella tabella 4.6 e 4.7 e nella figura 4.4 e 4.5, è l'incremento dei pixels, classificati come piante di mais, in particolare:

- nelle parcelle diserbate al 27,88%;
- nelle parcelle non diserbate al 16,18%;

Nelle parcelle diserbate, la rete neurale ha rilevato mediamente più pixels, classificati come piante di mais, rispetto alle parcelle non diserbate di circa 11,7%.

Tabella 4.6: media dei valori FVC (%) nelle parcelle diserbate del secondo volo ad altezza 10 m.

Parcella	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 1	34.3	0.1	34.4
D 2	21.4	0.5	21.9
D 3	32	0.3	32.3
D 4	23.8	7.6	31.4
Media	27.88	2.13	30.00
Deviazione St.	6.24	3.65	5.54

Tabella 4.7: *media dei valori FVC (%) nelle parcelle non diserbate del secondo volo ad altezza 10 m.*

Parcella	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
N 1	11	42.5	53.5
N 2	10.7	19.7	30.4
N 3	18	12.2	30.1
N 4	25	12.7	37.7
Media	16.18	21.78	37.93
Deviazione St.	6.78	14.23	10.96




Figura 4.4: *media dei valori FVC (%) nelle parcelle diserbate del secondo volo ad altezza 10 m.*




Figura 4.5: *media dei valori FVC (%) nelle parcelle non diserbate del secondo volo ad altezza 10 m.*

4.3 Differenza tra il primo volo con il secondo volo

4.3.1 Differenza tra le parcelle non diserbate del primo volo e del secondo volo a 10 m

Descrizione risultati

Nella tabella 4.8 e 4.9 e nelle figura 4.6 e 4.7, per quanto riguarda il valore dell'indice FVC (%) delle piante di mais, è possibile osservare un aumento significativo del numero di pixels, classificati come mais, in particolare passando da 1,58% a 16,18% con un incremento complessivo di 14,6%.

Per quanto riguarda le piante infestanti, è possibile notare un aumento dei pixels, classificati come malerbe, passando da un valore di 16,65% a 21,78%, con un incremento del 5,13%.

Tabella 4.8: valori FVC (%) delle parcelle non diserbate del primo volo ad altezza 10 m.

Parcelle	FVC (%) Mais	FVC (%) infestanti	FVC (%) totale
N 1	2.3	39.4	41.7
N 2	1.6	15.7	17.2
N 3	0.8	2.3	3.1
N 4	1.6	9.2	10.8
Media	1.58	16.65	18.20
Deviazione St.	0.61	16.12	16.69

Tabella 4.9: valori FVC (%) delle parcelle non diserbate del secondo volo ad altezza 10 m.

Parcelle	FVC (%) Mais	FVC (%) infestanti	FVC (%) totale
N 1	11	42.5	53.5
N 2	10.7	19.7	30.4
N 3	18	12.2	30.1
N 4	25	12.7	37.7
Media	16.17	21.77	37.92
Deviazione St.	6.78	14.23	10.96




Figura 4.6: *media dei valori FVC (%) del primo volo in parcelle non diserbate ad altezza 10 m.*




Figura 4.7: *media dei valori FVC (%) del secondo volo in parcelle non diserbate ad altezza 10 m.*

4.3.2 Differenza tra le parcelle diserbate del primo volo e del secondo volo a 10 m

Descrizione risultati

Nella tabella 4.10 e 4.11 e nelle figura 4.8 e 4.9, per quanto riguarda il valore dell'indice FVC (%) delle piante di mais, è possibile notare un significativo incremento del riconoscimento da parte della rete neurale dei pixels, classificati come piante di mais, in particolare:

- valore medio dell'indice FVC (%) mais per il primo volo: 1.43%;
- valore medio dell'indice FVC (%) mais per il secondo volo: 27.88%.

Complessivamente, dal primo al secondo volo, si osserva un incremento del valore medio dell'indice FVC (%) mais pari a 26,45%.

Allo stesso tempo, dal primo al secondo volo, possiamo osservare una significativa riduzione dei pixels, classificati come piante infestanti. Nel dettaglio possiamo notare:

- valore medio dell'indice FVC (%) Weed per il primo volo: 6.60%;
- valore medio dell'indice FVC (%) Weed per il secondo volo: 2.13%.

Inoltre, esaminando il grafico si osserva una riduzione del valore medio dell'indice FVC (%) Weed pari a 4,47%.

Tabella 4.10: valori FVC (%) delle parcelle non diserbate del primo volo ad altezza 10 m.

Parcelle	FVC (%) Mais	FVC (%) infestanti	FVC (%) totale
D 1	/	/	/
D 2	1.5	6.2	7.7
D 3	1.2	0	1.2
D 4	1.6	13.6	15.2
Media	1.43	6.60	8.03
Devianza St.	0.21	6.81	7.01

Tabella 4.11: valori FVC (%) delle parcelle diserbate del secondo volo ad altezza 10 m.

Parcelle	FVC (%) Mais	FVC (%) infestanti	FVC (%) totale
D 1	34.3	0.1	34.4
D 2	21.4	0.5	21.9
D 3	32	0.3	32.3
D 4	23.8	7.6	31.4
Media	27.88	2.13	30.00
Devianza St.	6.24	3.65	5.54




Figura 4.8: media dei valori FVC (%) del primo volo in parcelle diserbate ad altezza 10 m.




Figura 4.9: media dei valori FVC (%) del secondo volo in parcelle diserbate ad altezza 10 m.

4.3.3 Considerazione sulla differenza tra il primo volo con il secondo volo

Considerando che il primo volo è stato effettuato il 25 giugno 2018 ed il secondo volo il 7 luglio 2018 e considerando che il diserbo post-emergenza è stato distribuito il 28 giugno 2018:

- nel caso delle parcelle non diserbate, tra il primo ed il secondo volo, possiamo osservare una crescita significativa dell'indice FVC (%) Weed del 5,13%, passando da un valore di 16,65% a 21,78%;
- nel caso delle parcelle diserbate possiamo osservare una riduzione del valore medio dell'indice FVC (%) Weed pari a 4,47%, passando da 6.60% a 2.13%.

Allo stesso tempo possiamo osservare l'entità della differenza tra il valore medio dell'indice FVC (%) Weed per il primo volo delle parcelle non diserbate, il quale si attesta al 21.78%, rispetto a quello del secondo volo, il quale si aggira al 2.13% delle parcelle diserbate.

4.4 Dettaglio della performance della rete neurale in una parcella

A titolo di esempio abbiamo concentrato la nostra attenzione sulla parcella D2 ed in particolare nei confronti di un quadrante della parcella D2 per approfondire e comprendere meglio il possibile comportamento della rete neurale.

4.4.1 Parcella D2 del primo volo ed altezza 10 m

Descrizione risultati

La figura 4.12 si riferisce alla parcella D2, ossia la parcella diserbata, al primo volo a quota 10 m. Come è possibile notare nell'immagine centrale, la rete neurale non è riuscita ad identificare i pixels classificati come piante di mais. Tuttavia i pixels, annotati come piante infestanti, sono stati parzialmente rilevati.

Tabella 4.12: valori di FVC (%) della parcella D2 segmentata sia dalla rete neurale che manuale.

Parcella	Segmentazione	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 2	Rete neurale	1.5	6.2	7.7
D 2	Manuale	10	8.2	18.2




Figura 4.10: mappa di segmentazione dell'immagine della parcella diserbata: D2 del primo volo ad altezza 10 m. In verde: piante di mais; in giallo: piante infestanti; in nero: sfondo.



Figura 4.11: immagine della parcella D2 segmentata manualmente.

4.4.2 Quadrante della parcella D2 del primo volo ed altezza 10 m

Descrizione risultati

La figura 4.12 si riferisce ad un quadrante (1x1 m) della parcella D2. In questo caso la rete neurale, analizzando solamente un quadrante, ha prodotto risultati migliori:

- i pixels, classificati come piante infestanti, sono stati rilevati;
- i pixels, annotati come piante di mais, sono stati identificati parzialmente.

Tabella 4.10: valori di FVC (%) di un quadrante della parcella D2 segmentata sia dalla rete neurale che manuale.

Parcella	FVC (%) mais	FVC (%) infestanti	FVC (%) totale
D 2	11.6	17.8	29.4
D 2	12.6	18.2	30.8




Figura 4.12: segmentazione effettuata dalla rete neurale di un quadrante della parcella D2.



Figura 4.13: segmentazione manuale di un quadrante della parcella D2.

4.5 Confronto tra immagini segmentate dalla rete neurale e manualmente

Per valutare in maniera compiuta l'effettiva accuratezza attribuibile all'applicazione della rete neurale sono state confrontate le immagini (DIS-A e DIS-B) segmentate dalla rete neurale (RN) e manualmente (Umano) e sono stati eseguiti i seguenti test:

- Test normalità: FVC (%) Mais;
- Test normalità: FVC (%) Weed;
- Test normalità: FVC (%) Vegetazione totale.

Per entrambe le immagini (DIS-A e DIS-B) e per tutti gli indici FVC (%), è stato eseguito il “*Wilcoxon Test*” con l'unica eccezione dell'indice FVC (%) delle piante del mais dell'immagine DIS-B, in cui è stato effettuato il “*Test t Student*”, poiché i dati erano distribuiti normalmente.

I risultati dei test statistici sono riassunti nelle seguenti tabelle (per maggiori dettagli sull'elaborazione dei dati si veda l'Allegato):

Immagine DIS-A:

Tabella 4.11: *test normalità per ogni indice FVC (%).*

Test normalità	Mais (%) RN	Mais (%) Umano	Weed (%) RN	Weed (%) Umano	Total (%) RN	Total (%) Umano
D'Agostino & Pearson normality test						
P value	0.0026	0.1101	<0.0001	<0.0001	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	Yes	No	No	No	No
Shapiro-Wilk normality test						
P value	0.0431	0.1101	<0.0001	<0.0001	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No	No	No	No	No
KS normality test						
P value	>0.1000	0.0004	<0.0001	<0.0001	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	Yes	No	No	No	No	No

Tabella 4.11: *wilcoxon test per FVC (%) Mais, Weed e Total.*

Wilcoxon test	Rete neurale vs Umano
FVC (%) Mais	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes
FVC (%) Weed	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes
FVC (%) Total	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes

Immagine DIS-B:

Tabella 4.11: *test normalità per ogni indice FVC (%).*

Test normalità	Mais (%) RN	Mais (%) Umano	Weed (%) RN	Weed (%) Umano	Total (%) RN	Total (%) Umano
D'Agostino & Pearson normality test						
P value	0.7250	0.3874	>0.1000	>0.1000	0.6990	0.0009
Passed normality test (alpha=0.05)?	Yes	Yes	No	No	Yes	No
Shapiro-Wilk normality test						
P value	0.4752	0.2003	>0.1000	>0.1000	0.2294	0.0039
Passed normality test (alpha=0.05)?	Yes	Yes	No	No	Yes	No
KS normality test						
P value	>0.1000	>0.1000	>0.1000	>0.1000	>0.1000	0.0413
Passed normality test (alpha=0.05)?	Yes	Yes	No	No	Yes	No

Tabella 4.11: *test t Student per l'indice FVC (%) Mais.*

Test t Student	Rete neurale vs Umano
FVC (%) Mais	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes

Tabella 4.11: *wilcoxon test per l'indice FVC (%) Weed e Total.*

Wilcoxon test	Rete neurale vs Umano
FVC (%) Weed	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes
FVC (%) Total	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes

Immagine DIS-A:

Nella figura 4.14, relativamente al grafico del “*test t Student*” possiamo osservare per FVC (%) Mais: una riduzione statisticamente significativa dei pixels rilevati dalla rete neurale rispetto alla segmentazione manuale di circa 2%, passando dall’11,5% al 13,5%.

Nella figura 4.14, relativamente al grafico del test “*Wilcoxon test*” possiamo notare per FVC (%) Weed: una diminuzione statisticamente significativa dei pixels rilevati dalla rete neurale rispetto alla segmentazione manuale del 4%, passando dal 4% a 8%.

In sintesi, l’annotazione effettuata dalla rete neurale ha rilevato meno pixels, classificati come piante di mais e piante di infestanti, rispetto alla segmentazione manuale.




Figura 4.14: *test t Student*: $p < 0.0001$, $N = 88$; *Wilcoxon test*: $p < 0.0001$, $N = 88$.

Immagine DIS-B:

Nella figura 4.15, relativamente ai grafici dei test “*Wilcoxon test*” possiamo osservare per l’indice FVC (%) del mais un aumento statisticamente significativo dei pixels rilevati dalla rete neurale rispetto all’annotazione manuale del 7%, passando dal 41% rilevato dalla rete neurale al 34% rilevato manualmente. Per l’indice FVC (%) delle infestanti possiamo notare una riduzione statisticamente significativa dei pixels rilevati dalla rete neurale rispetto all’annotazione manuale di circa 3%, passando da ~2% a quasi ~5%.




Figura 4.15: *Wilcoxon test*; $p < 0.0001$, $N = 88$.

5. Discussione

5.1 Discussioni sulla differenza dei risultati di volo tra 10 m, 15 m e 20 m.

In questo paragrafo vengono discussi ed analizzati i risultati degli indici FVC (%), in particolare:

- FVC (%) Mais;
- FVC (%) Weed;
- FVC (%) Vegetazione totale.

5.1.1 FVC (%) Mais del primo volo

Dall'analisi dei risultati dell'indice FVC (%) del mais del primo volo, osservando il grafico della figura 5.1, possiamo notare che la rete neurale è stata in grado di rilevare mediamente più pixels, classificati come piante di mais, all'aumentare dell'altezza di volo in modo proporzionale. Dunque si può affermare che il volo a 20 metri mantiene le informazioni del volo a 10 metri, tuttavia la perdita di dettaglio causa una segmentazione di regioni verdi meno definite, che si concretizza in un riconoscimento più abbondante di pixels verdi. Le immagini acquisite a 15 metri si collocano in posizione intermedia, mentre, nelle immagini ottenute nei voli a 10 metri, i dati vengono mantenuti senza perdere molti dettagli. In sintesi, dato che la perdita di dettaglio aumenta proporzionalmente all'aumentare della quota di volo, ma in misura limitata, potrebbe essere più opportuno effettuare il volo ad un'altezza di 20 metri sempreché la percentuale di copertura di mais risultasse sottostimata rispetto alla realtà.




Figura 5.1: media dei valori FVC (%) del mais del primo volo a diverse altezze.

5.1.2 FVC (%) Weed del primo volo

Dall'analisi dei risultati dell'indice FVC (%) delle piante infestanti del primo volo, osservando il grafico della figura 5.2, possiamo notare che la rete neurale è stata in grado di rilevare significativamente più pixels, classificati come malerbe, nel volo a 20 m rispetto agli altri voli. In questo caso, possiamo affermare che il volo a 20 metri non mantiene le stesse informazioni del volo a 10 e 15 metri, poiché la perdita di dettaglio ha generato una maggiore segmentazione delle aree verdi. Tuttavia, nelle immagini ottenute a 10 e 15 metri, i dati vengono mantenuti senza perdere molti dettagli. In sintesi, dato che la perdita di dettaglio aumenta considerevolmente all'aumentare della quota di volo, soprattutto passando dai 15 ai 20 metri, sarebbe opportuno volare tra i 10 e i 15 metri sempreché la percentuale di copertura delle infestanti risultasse sottostimata rispetto alla realtà.




Figura 5.2: media dei valori FVC (%) delle infestanti del primo volo a diverse altezze.

5.1.3 FVC (%) Vegetazione totale del primo volo

Dall'analisi dei risultati dell'indice FVC (%) della vegetazione totale del primo volo, osservando il grafico della figura 5.3, possiamo notare che la rete neurale è stata in grado di rilevare significativamente più pixels, classificati come vegetazione totale, nel volo a 20 m rispetto alle altre quote di volo. Anche in questo caso possiamo affermare che il volo a 20 metri non mantiene le stesse informazioni dei voli a 10 e 15 metri. Mentre, in queste ultime immagini, i dati vengono mantenuti senza perdere molti dettagli. Complessivamente, possiamo osservare che i dati a 15 metri, sia nel rilevamento delle piante di mais che delle infestanti, vengono mantenuti senza perdere molti dettagli. In sintesi potrebbe essere opportuno effettuare il volo alla quota di 15 metri sempreché la percentuale di copertura della vegetazione risultasse sottostimata rispetto alla realtà.




Figura 5.3: media dei valori FVC (%) della vegetazione totale del primo volo a diverse altezze.

5.2 Differenza tra le parcelle diserbate e non diserbate dei voli a 10 m del secondo volo

Nei grafici, presenti nelle figure 5.4 e 5.5, è possibile notare una significativa differenza tra i pixels, classificati come piante infestanti, nelle parcelle diserbate e non diserbate. In particolare l'indice FVC (%) delle infestanti si attesta nelle parcelle diserbate al 2,13% e nelle parcelle non diserbate al 21,78%. Nelle parcelle diserbate possiamo osservare, quindi, una riduzione di circa 19,65% in termini assoluti del valore FVC (%) delle infestanti, rispetto alle parcelle non diserbate. Allo stesso tempo nelle parcelle diserbate possiamo rilevare una maggior quantità di pixels classificati come piante di mais. Pertanto possiamo affermare che il trattamento, effettuato tra il primo ed il secondo volo, ha prodotto risultati positivi sullo sviluppo della coltura, riducendo la quantità di piante infestanti e quindi il livello di competizione esercitato sul mais.




Figura 5.4: media dei valori FVC (%) nelle parcelle diserbate del secondo volo ad altezza 10 m.




Figura 5.5: media dei valori FVC (%) nelle parcelle non diserbate del secondo volo ad altezza 10 m.

5.3 Considerazioni sulle differenze osservate tra il primo e il secondo volo

Tenendo conto che tra il primo volo ed il secondo volo è stato effettuato il diserbo post-emergenza, abbiamo potuto interpretare il significato delle differenze registrate a carico dei valori di FVC (%).

È interessante valutare in questo caso il diverso trend fatto segnare dall'indice FVC del mais e delle infestanti fra le parcelle diserbate e non diserbate. Infatti mentre nel caso delle parcelle diserbate l'indice FVC del mais fa segnare un incremento rispetto a quello osservato sulle parcelle non diserbate (in particolare +26,45% per le parcelle diserbate contro +14,6% in quelle non diserbate), l'indice FVC delle infestanti presenta un andamento contrario. Infatti l'indice FVC delle infestanti cresce considerevolmente nella parcelle non diserbate e si riduce drasticamente nelle parcelle diserbate (in particolare - 4,47% per le parcelle diserbate contro +5,13% in quelle non diserbate).

Questi risultati sono facilmente spiegabili considerando proprio l'effetto del diserbo che riduce la pressione competitiva delle infestanti consentendo un maggior sviluppo della coltura.

5.4 Performance della rete neurale in una parcella ed in un quadrante

La figura 5.6 si riferisce sia alla parcella D2, ossia la parcella diserbata, al primo volo a quota 10 m, sia ad un quadrante della parcella D2. Per quanto riguarda la segmentazione della parcella D2, la rete neurale non è riuscita a riconoscere efficacemente i pixels occupati dalle piante di mais, tuttavia le piante infestanti sono state parzialmente rilevate. Per quanto riguarda la segmentazione del solo quadrante della parcella D2, la rete neurale ha prodotto risultati migliori, in cui le piante infestanti sono state rilevate correttamente e le piante di mais sono state in buona parte identificate. Sulla base di questi risultati possiamo affermare che la rete neurale non fornisce soluzioni di efficacia generalizzabile anche se su piccole porzioni di immagini può in alcuni casi consentire il raggiungimento di risultati apprezzabili.




Figura 5.6: immagine della parcella e del quadrante D2 del primo volo segmentata dalla rete neurale e manualmente. Quota: 10 m. In verde: piante di mais; in giallo: piante infestanti; in nero: sfondo.

5.5 Confronto tra immagini segmentate dalla rete neurale e manualmente

Immagine DIS-A:

Nella figura 5.7 possiamo osservare sia il grafico del “*test t Student*” sia i grafici del “*Wilcoxon test*”. In generale, la rete neurale ha identificato meno pixels, classificati sia come piante di mais che come piante infestanti, rispetto alla segmentazione manuale di circa 6%. Sulla base di questi grafici possiamo affermare che la rete neurale, relativamente all’immagine DIS-A, ossia un’immagine appartenente al primo volo su parcelle non diserbate, è riuscita ad identificare buona parte dei pixels classificati come piante di mais, mentre è riuscita solo parzialmente a rilevare le piante infestanti. Complessivamente i risultati ottenuti non consentono di promuovere il ricorso alla rete neurale come una metodologia in grado di discriminare con successo la vegetazione, separando le infestanti dalla pianta coltivata.




Figura 5.7: *test t Student*: $p < 0.0001$, $N = 88$; *Wilcoxon test*: $p < 0.0001$, $N = 88$.

Immagine DIS-B:

Nella figura 5.8, relativamente ai grafici dei test “*Wilcoxon test*” possiamo osservare un comportamento della rete neurale diverso rispetto a quanto accaduto nell’analisi dell’immagine precedente. Le piante di mais, classificate dalla rete neurale, sono state rilevate in maggior numero rispetto alla segmentazione manuale, tuttavia le piante infestanti sono state annotate in quantità inferiori a quanto risulta dalla segmentazione eseguita dall’operatore. Sulla base di questi grafici possiamo affermare che, anche relativamente all’immagine DIS-B, ossia un’immagine catturata in occasione del secondo volo su parcelle diserbate, la rete neurale non sembra rappresentare un modello sufficientemente affidabile per ottenere risultati attendibili.




Figura 5.8: *Wilcoxon test*; $p < 0.0001$, $N = 88$.

5.6 Difficoltà ambientali

Rispetto al primo volo, durante le analisi delle immagini del secondo volo sono state riscontrate diverse difficoltà:

- sovrapposizione delle foglie di mais;
- ombreggiamento delle piante di mais;
- movimento delle foglie a causa del vento.

In condizioni ambientali ideali, le attuali tecniche di elaborazione delle immagini generano risultati di segmentazione con un livello di accuratezza molto elevato. Tuttavia, in condizioni ambientali non favorevoli, il processo di segmentazione e di estrazione delle caratteristiche risulta più complesso, potendo compromettere la qualità dell'analisi e quindi i comportamenti agronomici che da tale analisi derivano.

Durante la crescita della coltura, si presenta sempre di più il problema della sovrapposizione delle foglie, rendendole poco distinguibili l'una dall'altra. L'occlusione e il danneggiamento delle foglie modificano le caratteristiche morfologiche e spettrali (Fernández-Quintanilla et al., 2018) degradando le possibilità di riconoscimento delle specie vegetali. Anche le caratteristiche morfologiche, tessiturali e spettrali delle foglie mutano nel corso della crescita e lo sviluppo della vegetazione riducendo conseguentemente le performance dei modelli di classificazione (Shaner e Beckie, 2014). Inoltre le diverse condizioni di illuminazione, le ombre della vegetazione e l'angolo generato dall'inclinazione solare possono influire direttamente sul colore della vegetazione penalizzando l'efficienza degli algoritmi di segmentazione (Bai et al. 2014). Per “varie condizioni di illuminazione” si fa riferimento alle condizioni meteorologiche, in particolare quando il cielo è nuvoloso o soleggiato. Nelle giornate nuvolose si riduce la componente rossa nell'immagine, mentre il colore del suolo si avvicina al verde scuro. Nelle giornate soleggiate invece si possono verificare ombreggiamenti generati dalla posizione del sole, causando errori nella classificazione dei pixels. In particolare, il sole può produrre un riflesso speculare nella foglia o nel terreno, conducendo ad una classificazione errata dei pixel interessati (Hamuda, 2016).

5.7 Confronto tra i diversi approcci

I metodi utilizzati per la classificazione delle immagini si basano sull'indice di colore, sulla segmentazione per soglia e sulla segmentazione per apprendimento. Gli approcci basati sull'indice di colore presentano diversi vantaggi quali, ad esempio, il fatto di essere semplici da applicare e da implementare, di non richiedere un tipo di addestramento particolare e di essere efficaci in normali condizioni di illuminazione. Inoltre, il tempo di calcolo che generalmente richiedono è ridotto e dunque risultano particolarmente indicati per l'uso in real-time. Tuttavia presentano anche degli svantaggi come, ad esempio, di non funzionare bene in condizioni di forte o scarsa illuminazione e di essere adatti per la segmentazione di immagini in cui il colore della pianta dominante è il verde. Inoltre possono produrre livelli di segmentazioni troppo elevati o, al contrario, insufficienti, soprattutto nel caso in cui venga utilizzato un singolo indice. La segmentazione per soglia è un metodo che si può adattare bene ad una particolare condizione ambientale, ma che non può essere utilizzato per altre senza essere nuovamente calibrato. Pertanto nel caso in cui le condizioni ambientali mutano possono verificarsi errori di segmentazione che compromettono la qualità del risultato finale. Gli approcci che si basano sul *machine learning* o sul *deep learning* producono generalmente prestazioni migliori rispetto agli altri metodi, soprattutto quando si operi in condizioni di illuminazioni mutevoli perché si basano su una precedente fase di addestramento. Tuttavia il superamento di questa fase comporta un incremento del tempo di calcolo e, dunque, rende il metodo non utilizzabile nel caso di applicazioni in tempo reale (Hamuda et al., 2016).

6. Conclusioni

Alla luce dei risultati ottenuti possiamo affermare che la rete neurale utilizzata, U-net, ha dimostrato alcuni limiti rispetto alla capacità di discriminare, all'interno della vegetazione, le piante di mais dalle piante infestanti.

La rete neurale, come tutti i modelli basati sul *deep learning*, richiede la disponibilità di un dataset di apprendimento molto ampio affinché la rete neurale possa fornire buone performance. Inoltre, la scelta di ricorrere a metodologie di classificazione basate sull'apprendimento comporta un lavoro estremamente oneroso da parte dell'operatore, richiedendo molto tempo e molta attenzione. Infine l'elaborazione basata sul *deep learning* risulta abbastanza impegnativa anche a livello computazionale, non solo per l'addestramento della rete neurale, ma anche durante le fasi di utilizzo operativo (Zhou et al., 2019).

In conclusione, si ritiene che il ricorso a tecniche più sofisticate di riconoscimento delle infestanti (quali il *deep-learning* o il *machine-learning*) sia giustificato solo nel caso di gestire le successive operazioni di diserbo attraverso macchine a rateo variabile in grado di interpretare una mappa di prescrizione derivata da una corrispondente mappa di infestazione. Viceversa, nel caso in cui l'utilizzo dei droni alla valutazione dell'incidenza dell'infestazione sia finalizzato alla corretta determinazione della soglia economica di intervento, il ricorso a metodologie più speditive di classificazione (classificazione per soglia) sembra poter assicurare risultati accettabili con un notevole risparmio di tempo e di denaro.

Ulteriori sfide dunque devono ancora essere affrontate prima di poter rendere “conveniente” il ricorso a metodologie di intelligenza artificiale e a tecniche di agricoltura di precisione; più “matura” appare invece la possibilità di integrare la sensoristica su drone all'interno dei processi decisionali che l'agricoltore deve elaborare per una corretta gestione del diserbo chimico nella coltivazione delle colture agrarie.

7. Bibliografia

Ahmed, F., Al-Mamun, H.A., Bari, A.S.M.H., Hossain, E., Kwan, P., 2012. Classification of crops and weeds from digital images: a support vector machine approach. *Crop Prot.* 40, 98–104.

Akbarzadeh, S., Paap, A., Ahderom, S., Apopei, B., Alameh, K., 2018. Plant discrimination by Support Vector Machine classifier based on spectral reflectance. *Comput. Electron. Agric.* 148, 250–258

Alexandratos N, Bruinsma J. World agriculture towards 2030/2050: the 2012 revision. Rome: Food and Agriculture Organization of the UN, 2012.

AlSuwaidi, A., Veys, C., Hussey, M., Grieve, B., Yin, H., 2016. Hyperspectral selection based algorithm for plant classification. In: 2016 IEEE International Conference on Imaging Systems and Techniques (IST). IEEE, pp. 395–400

Ashok Kumar, D., Prema, P., 2013. A Review on Crop and Weed Segmentation Based on Digital Images. Springer, New Delhi, pp. 279–291.

Aware, A.A., Joshi, K., 2015. Wavelet based crop detection and automatic spraying of herbicides. *Int. J. Innov. Adv. Comput. Sci.* 4, 2–7.

Bai, X., Cao, Z., Wang, Y., Yu, Z., Hu, Z., Zhang, X., Li, C., 2014. Vegetation segmentation robust to illumination variations based on clustering and morphology modelling. *Biosyst. Eng.* 125, 80–97.

Bakhshipour, A., Jafari, A., Nassiri, S.M., Zare, D., 2017. Weed segmentation using texture features extracted from wavelet sub-images. *Biosyst. Eng.* 157, 1–12

Bakhshipour, A., Jafari, A., 2018. Evaluation of support vector machine and artificial A. Wang, et al. *Computers and Electronics in Agriculture* 158 (2019) 226–240 237 neural networks in weed detection using shape features. *Comput. Electron. Agric.* 145, 153–160.

Basso B, Cammarano D, Cafiero G, Marino S, Alvino A, 2011. Cultivar discrimination at different site elevations with remotely sensed vegetation indices. *Italian Journal of Agronomy* 6:e1.

- Behmann, J., Mahlein, A.K., Rumpf, T., Römer, C., Plümer, L., 2015. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Agric. Precis.*
- Bharati, M.H., Liu, J.J., MacGregor, J.F., 2004. Image texture analysis: methods and comparisons. *Chemom. Intell. Lab. Syst.* 72, 57–71
- Bietresato M., *La meccanica agraria oggi*, 2017
- Bishop Christopher M., *Pattern recognition and machine learning*, Springer, 2006
- Brown, R.B., Noble, S.D., 2005. Site-specific weed management: sensing requirements - what do we need to see? *Weed Sci.* 53, 252–258.
- Burgos-Artizzu, X.P., Ribeiro, A., Guijarro, M., Pajares, G., 2011. Real-time image processing for crop/weed discrimination in maize fields. *Comput. Electron. Agric.* 75 (2), 337–346.
- Caporali F., *ecologia per l'agricoltura. Teoria e pratica*, 1991.
- Chaki, J., Parekh, R., Bhattacharya, S., 2015. Plant leaf recognition using texture and shape features with neural classifiers. *Pattern Recognit. Lett.* 58, 61–68
- Cheng, H.D., Jiang, X.H., Sun, Y., Wang, J., 2001. Color image segmentation: advances and prospects. *Pattern Recognit.* 34, 2259–2281.
- Cheng, B., Matson, E.T., 2015. *A Feature-Based Machine Learning Agent for Automatic Rice and Weed Discrimination*. Springer, Cham, pp. 517–527.
- Colomina, I., Molina, P. (2014), Unmanned aerial system for photogrammetry and remote sensing: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, pp. 79-97.
- Coudel, E., Devautour, H., Soulard, C. T., Faure, G., Hubert, B. (Eds.), 2013. *Renewing innovation systems in agriculture and food: How to go towards more sustainability?*. Wageningen Academic Publishers, Wageningen.
- De Castro, A.I., Jurado-Expósito, M., Peña-Barragán, J.M., López-Granados, F.: Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. *Precis. Agric.* 13(3), 302–321 (2012).

De Mauro Andrea., Big data analytics: guida per iniziare a classificare e interpretare dati con il machine learning, Apogeo, 2019

Di Lucia F., Nuove tecnologie per la green economy: utilizzo di drone in agricoltura e studi per l'utilizzo di *Nicotiana tabacum* L. come coltura oleaginosa, 2016

Farhana Sultana, Abu Sufiana Paramartha Duttat. Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey (2020)

Ferrari G., Fresco, enhancing precision agriculture by internet of things and cyber physical systems, 2018.

Fernández-Quintanilla, C., Peña, J.M., Andújar, D., Dorado, J., Ribeiro, A., LópezGranados, F., 2018. Is the current state of the art of weed monitoring suitable for sitespecific weed management in arable crops? *Weed Res.* 58, 259–272

Gabriele Andrea, 2019, Data-Driven Design e le opportunità di automatizzazione dei processi di progettazione

Gebhardt, S., Schellberg, J., Lock, R., Kaühbauch, W.A., 2006. Identification of broadleaved dock (*Rumex obtusifolius* L.) on grassland by means of digital image processing. *Precision Agric.* 7 (3), 165–178.

Gebhardt, S., Kaühbauch, W.A., 2007. A new algorithm for automatic *Rumex obtusifolius* detection in digital image using colour and texture features and the influence of image resolution. *Precision Agric.* 8 (1), 1–13.

Gerhards R, Christensen S. 2003. Real-time weed detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley. *Weed research* 43: 385-92

Gonzalez, R.C., Woods, R.E., 2007. Image processing. *Digit. image Process.*

Guerrero, J.M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M., 2012. Support vector machines for crop/weeds identification in maize fields. *Exp. Syst. Appl.* 39, 11149–11155.

Guijarro, M., Pajares, G., Riomoros, I., Herrera, P.J., Burgos-Artizzu, X.P., Ribeiro, A., 2011. Automatic segmentation of relevant textures in agricultural images. *Comput. Electron. Agric.* 75, 75–83

- Guo, W., Rage, U.K., Ninomiya, S., 2013. Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model. *Comput. Electron. Agric.* 96, 58–66.
- Hague, T., Tillett, N., Wheeler, H., 2006. Automated crop and weed monitoring in widely spaced cereals. *Precision Agric.* 1 (1), 95–113.
- Hall, D., Dayoub, F., Kulk, J., McCool, C., 2017. Towards unsupervised weed scouting for agricultural robotics. In: *Robotics and Automation (ICRA), 2017 IEEE International Conference On. IEEE*, pp. 5223–5230.
- Hamuda, E., Glavin, M., & Jones, E. (2016). A survey of image processing techniques for plant extraction and segmentation in the field. *Computers and Electronics in Agriculture*, 125, 184–199.
- Hamuda, E., McGinley, B., Glavin, M., Jones, E., 2017. Automatic crop detection under field conditions using the HSV colour space and morphological operations. *Comput. Electron. Agric.* 133, 97–107
- Hao, P., Wang, L., Niu, Z., 2015. Comparison of hybrid classifiers for crop classification using normalized difference vegetation index time series: a case study for major crops in North Xinjiang, China. *PLoS One* 10, e0137748–24.
- Haralick, R.M., Shanmugam, K., Dinstein, I., 1973. Textural features for image classification. *IEEE Trans. Syst. Man. Cybern.* SMC-3, 610–621
- Hassanein, M., Lari, Z., El-Sheimy, N., Hassanein, M., Lari, Z., El-Sheimy, N., 2018. A new vegetation segmentation approach for cropped fields based on threshold detection from hue histograms. *Sensors* 18, 1253.
- Hemming, J., Rath, T., 2001. PA-precision agriculture. Computer-vision-based weed identification under field conditions using controlled lighting. *J. Agric. Eng. Res.* 78 (3), 233–243.
- Herrmann, I., Shapira, U., Kinast, S., Karnieli, A., Bonfil, D.J., 2013. Ground-level hyperspectral imagery for detecting weeds in wheat fields. *Precision Agric.* 14, 637–659.
- Herrera, P., Dorado, J., Ribeiro, A., 2014. A novel approach for weed type classification based on shape descriptors and a fuzzy decision-making method. *Sensors* 14, 15304–15324

Historic England (2018 b), Using Airborne Lidar in Archaeological Survey: The Light Fantastic. Swindon.

Hunt, E.R., Cavigelli, M., Daughtry, C.S.T., McMurtrey, J.E., Walthall, C.L., 2005. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. *Precision Agric.* 6, 359–378.

Jeon, Gwanggil, 2014. Color image enhancement by histogram equalization in heterogeneous color space. *Int. J. Multimedia Ubiquitous Eng.* 9 (7), 309–318.

Jeon, Hong Y., Tian, Lei F., Zhu, Heping, 2011. Robust crop and weed segmentation under uncontrolled outdoor illumination. *Sensors* 11 (12), 6270–6283

Kataoka, T., Kaneko, T., Okamoto, H., Hata, S., 2003. Crop growth estimation system using machine vision. *Proc. 2003 IEEE/ASME Int. Conf. Adv. Intell. Mechatronics (AIM 2003)*, vol. 2, pp. 1079–1083.

Kaur, D., Kaur, Y., 2014. Various image segmentation techniques: a review. *Int. J. Comput. Sci. Mob. Comput.* 3, 809–814

Kazmi, W., Garcia-Ruiz, F., Nielsen, J., Rasmussen, J., Andersen, H.J., 2015. Exploiting affine invariant regions and leaf edge shapes for weed detection. *Comput. Electron. Agric.* 118, 290–299.

Kirk, K., Andersen, H.J., Thomsen, A.G., Jørgensen, J.R., 2009. Estimation of leaf area index in cereal crops using red–green images. *Biosyst. Eng.* 104, 308– 317

Kumar, D.A., Prema, P., 2016. A novel wrapping curvelet transformation based angular texture pattern (WCTATP) extraction method for weed identification. *ICTACT J. Image Video Process.* 6

Lameski et al. - 2018 - Review of Automated Weed Control Approaches An En.

Lamm, R.D., Slaughter, D.C., Giles, D.K., 2002. Precision weed control for cotton. *Trans. ASAE* 45, 231–238.

Li, P., He, D., Qiao, Y., Yang, C., 2013. An application of soft sets in weed identification, in: 2013 Kansas City, Missouri, July 21 - July 24, 2013. American Society of Agricultural and Biological Engineers, St. Joseph, MI, p. 1.

- Li F, Miao Y, Feng G, Yuan F, Yue S, Gao X, Liu L, Liu B, Ustin SL, Chen X, 2014. Improving estimation of summer maize nitrogen status with red edge based spectral vegetation indices. *Field Crop. Res.* 157: 11-123.
- Lin, C., 2009. A support vector machine embedded weed identification system. University of Illinois at Urbana-Champaign.
- Ling, P.P., Ruzhitsky, V.N., 1996. Machine vision techniques for measuring the canopy of tomato seedling. *J. Agric. Eng. Res.* 65 (2), 85–95.
- Liu, Lee, S.H., Saunders, C., 2014. Development of a machine vision system for weed detection during both off-sean and in-season in broadacre no-tillage cropping lands. *Am. J. Agric. Biol. Sci.* 9, 174–193
- Loghavi, M., Mackvandi, B.B.: Development of a target oriented weed control system. *Comput. Electron. Agric.* 63(2), 112–118 (2008).
- Marchant, J.A., Tillett, R.D., Brivot, R., 1998. Real-time segmentation of plants and weeds. *Real-Time Imaging* 4 (4), 243–253.
- Marino S, Aria M, Basso B, Leone AP, Alvino A, 2014a. Use of soil and vegetation spectroradiometry to investigate crop water use efficiency of a drip irrigated tomato. *Eur. J. Agron.* 59: 67-77.
- Marino S, Coccozza C, Tognetti R, Alvino A, 2015a. Use of proximal sensing and vegetation indexes to detect the inefficient spatial allocation of drip irrigation in a spot area of tomato field crop. *Precis. Agric.* 16: 613-629.
- Materka, A., Strzelecki, M., 1998. Texture analysis methods – A review. *Methods* 11, 1–33.
- Mathanker, S.K., Weckler, P.R., Taylor, R.K., Fan, G., 2010. Adaboost and Support Vector Machine Classifiers for Automatic Weed Control: Canola and Wheat. In: 2010 Pittsburgh, Pennsylvania, June 20 - June 23, 2010. American Society of Agricultural and Biological Engineers, St. Joseph, MI, p. 1
- Meola, C., Carlomagno, G. M. (2004), Recent advances in the use of infrared thermography, *Measurement Science And Technology*, 15, pp. 27-58.

- Meyer, G.E., Hindman, T.W., Lakshmi, K., 1998. Machine vision detection parameters for plant species identification. In: Meyer, G.E., DeShazer, J.A. (Eds.), *Precision Agriculture and Biological Quality*, Proceedings of SPIE. vol. 3543, Bellingham, WA, pp. 327–335.
- Meyer, G.E., Camargo-Neto, J., Jones, D.D., Hindman, T.W., 2004. Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. *Comput. Electron. Agric.* 42, 161–180.
- Meyer, G.E., Camargo-Neto, J., 2008. Verification of color vegetation indices for automated crop imaging applications. *Comput. Electron. Agric.* 63, 282–293.
- Midtiby, H.S., Åstrand, B., Jørgensen, O., Jørgensen, R.N., 2016. Upper limit for context-based crop classification in robotic weeding applications. *Biosyst. Eng.* 146, 183–192.
- Ming-Kuei, Hu., 1962. Visual pattern recognition by moment invariants. *IEEE Trans. Inf. Theory* 8, 179–187
- Minucci, 2018, Apr e droni nella moderna ricerca archeologica: un primo approccio
- Onyango, C.M., Marchant, J.A., 2003. Segmentation of row crop plants from weeds using colour and morphology. *Comput. Electron. Agric.*
- Nieto HJ, Brondo M, Gonzalez J. 1968. Critical periods of the crop growth cycle for competition from weeds.
- Oerke EC (2006). Crop losses to pests. *Journal of Agricultural Science* 144: 31-43
- Otsu, N., 1979. A threshold selection method from gray-level histogram. *IEEE Trans. Syst. Man Cybern.* 9, 62–66.
- Pereira, L.A.M., Nakamura, R.Y.M., de Souza, G.F.S., Martins, D., Papa, J.P., 2012. Aquatic weed automatic classification using machine learning techniques. *Comput. Electron. Agric.* 87, 56–63.
- Pena J. M., J. Torres-Sánchez, A. I. de Castro, M. Kelly, and F. López-Granados. Weed mapping in early-season maize fields using objectbased analysis of unmanned aerial vehicle uav images. *PLoS ONE*, 8, 2013.

- Potena, C., Nardi, D., Pretto, A., 2017. Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture. In: *Advances in Robot Design and Intelligent Control*. Springer International Publishing, Cham, pp. 105–121.
- Prema, P., Murugan, D., 2016. A Novel Angular Texture Pattern (ATP) extraction method for crop and weed discrimination using curvelet transformation. *ELCVIA Electron. Lett. Comput. Vis. Image Anal.* 15, 27–59
- Rasmussen, J., Nørremark, M., Bibby, B., 2007. Assessment of leaf cover and crop soil cover in weed harrowing research using digital images. *Weed Res.* 47, 299–310
- Reid, J., Searcy, S., 1987. Vision-based guidance of an agricultural tractor. *IEEE Control Syst. Mag.* 7 (2), 39–43.
- Ribeiro, A., Fernández-Quintanilla, C., Barroso, J., García-Alegre, M.C., 2005. Development of an image analysis system for estimation of weed. In: *Proceedings of the 5th European Conference on Precision Agriculture (5ECPA)*, pp. 169–174.
- Sabzi, S., Abbaspour-Gilandeh, Y., García-Mateos, G., 2018. A fast and accurate expert system for weed identification in potato crops using metaheuristic algorithms. *Comput. Ind.* 98, 80–89
- Shaner, D.L., Beckie, H.J., 2014. The future for weed control and technology. *Pest Manag. Sci.* 70, 1329–1339.
- Sahoo, R.K., Soltani, S., Wong, K.C., Chen, Y.C., 1988. A survey of thresholding techniques. *Comput. Vision, Graph., Image Process.* 41, 233–260.
- Schuster, I., Nordmeyer, H., Rath, T., 2007. Comparison of vision-based and manual weed mapping in sugar beet. *Biosyst. Eng.*
- Shrestha, D.S., Steward, B.L., Birrell, S.J., 2004. Video processing for early stage maize plant detection. *Biosyst. Eng.* 89 (2), 119–129.
- Siddiqi, Muhammad Hameed, Seok-Won Lee, A.M.K., 2014. Weed image classification using wavelet transform, stepwise linear discriminant analysis and support vector machines for an automatic spray control system. *J. Inf. Sci. Eng.* 30, 1253–1270.
- Silva B. L'agricultura 4.0, 2018

- Singh, A., Ganapathysubramanian, B., Singh, A.K., Sarkar, S., 2016. Machine learning for high-throughput stress phenotyping in plants. *Trends Plant Sci.*
- Singh OV, Ghai S, Paul D, Jain RK. 2006. Genetically modified crops: success, safety assessment, and public concern. *Applied microbiology and biotechnology* 71: 598-607
- Slaughter, D.C., Giles, D.K., Downey, D., 2008. Autonomous robotic weed control systems: a review. *Comput. Electron. Agric.* 61, 63–78.
- Slaughter, D.C., 2013. The Biological Engineer: Sensing the Difference Between Crops and Weeds. In: *Automation: The Future of Weed Control in Cropping Systems*. Springer, Netherlands, Dordrecht, pp. 71–95.
- Søgaard, H.T., 2005. Weed classification by active shape models. *Biosyst. Eng.*
- Tang, J., Chen, X.-Q., Miao, R.-H., Wang, D., 2016. Weed detection using image processing under different illumination for site-specific areas spraying. *Comput. Electron. Agric.* 122, 103–111. Tang, J., Wang, D., Zhang, Z.
- Tang, J., Wang, D., Zhang, Z., He, L., Xin, J., Xu, Y., 2017. Weed identification based on Kmeans feature learning combined with convolutional neural network. *Comput. Electron. Agric.* 135, 63–70.
- Tang, J., Zhang, Z., Wang, D., Xin, J., He, L., 2018. Research on weeds identification based on K-means feature learning. *Soft Comput.* 1–10.
- Tian, Slaughter, 1998. Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Comput. Electron. Agric.* 21, 153–168.
- Van Gerven, M., Bohte, S., 2018. Artificial neural networks as models of neural information processing. *Frontiers Media SA.*
- Ventura, Antonino, 2020, Estrazione di relazioni semantiche frequenti tra oggetti in immagini segmentate.
- Vidotto F, Ferrero A (2009). Interactions between weedy rice and cultivated rice in Italy. *Italian Journal of Agronomy* 4: 127-136.
- Vurro M., Cristofaro M., Casella F., Boari A., Zonno M.C., Lotta biologica alle piante infestanti, 2008

- Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158, 226–240.
- Weis, M., Sökefeld, M., 2010. Detection and Identification of Weeds. In: *Precision Crop Protection - the Challenge and Use of Heterogeneity*. Springer, Netherlands, Dordrecht, pp. 119–134.
- Woebbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D., 1992. Plant species identification, size, and enumeration using machine vision techniques on nearbinary images. *SPIE Opt. Agric. Forestry* 1836, 208–219.
- Woebbecke, D., Meyer, G., VonBargen, K., Mortensen, D., 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Trans. ASAE* 38 (1), 271–281.
- Wu, L., Wen, Y., 2009. Weed/corn seedling recognition by support vector machine using texture features. *African J. Agric. Res.* 4, 840–846
- Zanin G, Berti A, Giannini M (1992). Economics of herbicide use on arable crops in North–Central Italy. *Crop Protection* 11: 174-180.
- Zhang, J., Tan, T., 2002. Brief review of invariant texture analysis methods. *Pattern Recognit.* 35, 735–747
- Zheng, L., Zhang, J., Wang, Q.y., 2009. Mean-shift-based color segmentation of images containing green vegetation. *Comput. Electron. Agric.* 65, 93–98.
- Zheng, L., Shi, D., Zhang, J., 2010. Segmentation of green vegetation of crop canopy images based on mean shift and Fisher linear discriminate. *Pattern Recogn. Lett.* 31 (9), 920–925.
- Zhou Z., Md Mahfuzur Rahman Siddiquee, Nima Tajbakhsh, Jianming Liang, UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation, 2019
- Zoeschke A, Quadranti M (2002). Integrated weed management-quo vadis?. *Weed Biology and Management* 2: 1-10. Zoeschke A, Quadranti M (2002). Integrated weed management-quo vadis?. *Weed Biology and Management* 2: 1-10.
- Zorzan Riccardo. Sviluppo di un algoritmo basato su tecniche di deep learning per la segmentazione di cellule dendritiche in immagini della cornea. (2020).

Sitografia

CNR – ISTI: <http://si.isti.cnr.it/>

ENAC: <https://www.enac.gov.it/>

FAO FAOSTAT. Available online: <http://www.fao.org/faostat/en/#data/QC>, 2017

Linee guida del *Gruppo di Lavoro per lo sviluppo dell'Agricoltura di Precisione* D.M. 1 settembre 2015 del Ministero delle Politiche Agricole Alimentari e Forestali

8. Allegato

Immagine DIS-A

Test normalità: FVC (%) Mais

	MAIS (%) Rete neurale	MAIS (%) Umano
Number of values	88	88
Minimum	0.1	3.1
25% Percentile	8.2	11.05
Median	10.55	12.65
75% Percentile	13.88	15.78
Maximum	29.6	23.7
Mean	11.13	13.28
Std. Deviation	4.84	3.705
Std. Error of Mean	0.5159	0.395
Sum	979	1169
D'Agostino & Pearson normality test		
K2	11.88	4.412
P value	0.0026	0.1101
Passed normality test (alpha=0.05)?	No	Yes
P value summary	**	ns
Shapiro-Wilk normality test		
W	0.9707	0.9618
P value	0.0431	0.0109
Passed normality test (alpha=0.05)?	No	No
P value summary	*	*
KS normality test		
KS distance	0.07282	0.1356
P value	>0.1000	0.0004
Passed normality test (alpha=0.05)?	Yes	No
P value summary	ns	***

Test normalità: FVC (%) Weed

	WEED (%) Rete neurale	WEED (%) Umano
Number of values	88	88
Minimum	0	0
25% Percentile	0	0.825
Median	0.55	2.95
75% Percentile	3.925	10
Maximum	56.5	61.3
Mean	4.073	7.727
Std. Deviation	8.93	11.15
Std. Error of Mean	0.952	1.189
Sum	358.4	680
D'Agostino & Pearson normality test		
K2	96.97	61.61
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
Shapiro-Wilk normality test		
W	0.507	0.6925
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
KS normality test		
KS distance	0.3242	0.2442
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****

Test normalità: FVC (%) Vegetazione totale

	TOTAL (%) Rete neurale	TOTAL (%) Umano
Number of values	88	88
Minimum	0.5	7.3
25% Percentile	9.225	13.9
Median	12.75	17.3
75% Percentile	18.18	24.68
Maximum	65.8	73.8
Mean	15.2	21.01
Std. Deviation	9.68	11.3
Std. Error of Mean	1.032	1.204
Lower 95% CI of mean	13.15	18.62
Upper 95% CI of mean	17.25	23.4
Sum	1337	1849
D'Agostino & Pearson normality test K2	66.55	54.96
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
Shapiro-Wilk normality test W	0.7901	0.7854
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
KS normality test KS distance	0.173	0.1779
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****

Wilcoxon test: FVC (%) Mais

	Data Set-A
Table Analyzed	Percentuale mais 7184
Column B vs. Column A	MAIS(%) Umano vs. MAIS(%) Rete neurale
Wilcoxon matched-pairs signed rank test	
P value	<0.0001
Exact or approximate P value?	Exact
P value summary	****
Significantly different (P < 0.05)?	Yes
One- or two-tailed P value?	Two-tailed
Sum of positive, negative ranks	3140 , -776.5
Sum of signed ranks (W)	2363
Number of pairs	88
Median of differences	
Median	1.85
How effective was the pairing?	
rs (Spearman)	0.6049
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes

Wilcoxon test: FVC (%) Weed

	Data Set-A
Table Analyzed	Percentuale infestanti 7184
Column B vs. Column A	WEED(%) Umano vs. WEED(%) Rete neurale
Wilcoxon matched-pairs signed rank test	
P value	<0.0001
Exact or approximate P value?	Exact
P value summary	****
Significantly different (P < 0.05)?	Yes
One- or two-tailed P value?	Two-tailed
Sum of positive, negative ranks	2830 , -20.5
Sum of signed ranks (W)	2809
Number of pairs	88
Median of differences	
Median	2.3
How effective was the pairing?	
rs (Spearman)	0.818
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes

Wilcoxon test: FVC (%) Vegetazione totale

	Data Set-A
Table Analyzed	Percentuale totale 7184
Column B vs. Column A	TOTAL (%) Umano vs. TOTAL (%) Rete neurale
Wilcoxon matched-pairs signed rank test	
P value	<0.0001
Exact or approximate P value?	Exact
P value summary	****
Significantly different (P < 0.05)?	Yes
One- or two-tailed P value?	Two-tailed
Sum of positive, negative ranks	3691 , -225
Sum of signed ranks (W)	3466
Number of pairs	88
Median of differences	
Median	5.1
How effective was the pairing?	
rs (Spearman)	0.6409
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes

Immagine DIS-B

Test normalità: FVC (%) Mais

	MAIS (%) Rete neurale	MAIS (%) Umano
Number of values	88	88
Minimum	0.6	7.1
25% Percentile	28.9	26.68
Median	39.4	31.9
75% Percentile	52.4	40.1
Maximum	77.2	57.1
Mean	40.61	33.44
Std. Deviation	15.24	9.929
Std. Error of Mean	1.624	1.058
Sum	3573	2943
D'Agostino & Pearson normality test		
K2	0.6432	1.897
P value	0.7250	0.3874
Passed normality test (alpha=0.05)?	Yes	Yes
P value summary	ns	ns
Shapiro-Wilk normality test		
W	0.9861	0.9803
P value	0.4752	0.2003
Passed normality test (alpha=0.05)?	Yes	Yes
P value summary	ns	ns
KS normality test		
KS distance	0.07866	0.08042
P value	>0.1000	>0.1000
Passed normality test (alpha=0.05)?	Yes	Yes
P value summary	ns	ns

Test normalità: FVC (%) Weed

	WEED (%) Rete neurale	WEED (%) Umano
Number of values	88	88
Minimum	0	0
25% Percentile	0	0
Median	0	0.25
75% Percentile	0.3	4.825
Maximum	27.5	59
Mean	1.776	4.618
Std. Deviation	5.112	9.726
Std. Error of Mean	0.5449	1.037
Sum	156.3	406.4
D'Agostino & Pearson normality test		
K2	94.52	86.17
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
Shapiro-Wilk normality test		
W	0.3995	0.5371
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****
KS normality test		
KS distance	0.4053	0.3174
P value	<0.0001	<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	****	****

Test normalità: FVC (%) Vegetazione totale

	TOTAL (%) Rete neurale	TOTAL (%) Umano
Number of values	88	88
Minimum	0.8	15.7
25% Percentile	30.7	29.28
Median	39.7	35.8
75% Percentile	54.43	45.38
Maximum	77.3	86.1
Mean	42.38	38.06
Std. Deviation	16.15	13.08
Std. Error of Mean	1.721	1.394
Sum	3730	3349
D'Agostino & Pearson normality test		
K2	0.7161	14.06
P value	0.6990	0.0009
Passed normality test (alpha=0.05)?	Yes	No
P value summary	ns	***
Shapiro-Wilk normality test		
W		
P value	0.9811	0.9549
Passed normality test (alpha=0.05)?	0.2294	0.0039
P value summary	Yes	No
	ns	**
KS normality test		
KS distance		
P value	0.07912	0.09666
Passed normality test (alpha=0.05)?	>0.1000	0.0413
P value summary	Yes	No
	ns	*

Test t student: FVC (%) Mais

	Data Set-A
Table Analyzed	Percentuale mais 7038
Column B vs. Column A	MAIS(%) Umano vs. MAIS(%) Rete neurale
Paired t test	
P value	<0.0001
P value summary	****
Significantly different (P < 0.05)?	Yes
Number of pairs	88
How big is the difference?	
Mean of differences	-7.166
SD of differences	8.713
SEM of differences	0.9288
95% confidence interval	-9.012 to -5.32
R squared (partial eta squared)	0.4062
How effective was the pairing?	
Correlation coefficient (r)	0.8422
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes

Wilcoxon test: FVC (%) Weed

	Data Set-A
Table Analyzed	Percentuale infestanti 7038
Column B vs. Column A	WEED(%) Umano vs. WEED(%) Rete neurale
Wilcoxon matched-pairs signed rank test	
P value	<0.0001
Exact or approximate P value?	Exact
P value summary	****
Significantly different ($P < 0.05$)?	Yes
One- or two-tailed P value?	Two-tailed
Sum of positive, negative ranks	1578 , -75
Sum of signed ranks (W)	1503
Number of pairs	88
Median of differences	
Median	0.2
How effective was the pairing?	
rs (Spearman)	0.6273
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes

Wilcoxon test: FVC (%) Vegetazione totale

	Data Set-A
Table Analyzed	percentuale totale 7038
Column B vs. Column A	TOTAL(%) Umano vs. TOTAL(%) Rete neurale
Wilcoxon matched-pairs signed rank test	
P value	<0.0001
Exact or approximate P value?	Exact
P value summary	****
Significantly different (P < 0.05)?	Yes
One- or two-tailed P value?	Two-tailed
Sum of positive, negative ranks	944 , -2884
Sum of signed ranks (W)	-1940
Number of pairs	88
Median of differences	
Median	-5.6
How effective was the pairing?	
rs (Spearman)	0.775
P value (one tailed)	<0.0001
P value summary	****
Was the pairing significantly effective?	Yes